

**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ**  
**ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ**  
**ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**



**Διπλωματική Εργασία**

---

**Μια Αρχιτεκτονική Βαθιάς Μηχανικής Μάθησης  
για Φιλτράρισμα και Ταξινόμηση Δεδομένων  
σε ΗΕΓ Νοερής Κίνησης**

---

Του φοιτητή

Λυτρίδη Νικόλαου

Αρ. Μητρώου: 2009030088

Επιτροπή

Αν. Καθ. Λαγουδάκης Μιχαήλ

Καθ. Ζερβάκης Μιχαήλ

Δρ. Διακολουκάς Βασίλειος

**Χανιά 2020**



## Περίληψη

Η Διεπαφή Εγκεφάλου-Υπολογιστή (ΔΕΥ) ή Brain-Computer Interface (BCI) είναι ένας επιστημονικός τομέας, ο οποίος με την ανάπτυξη νέων τεχνολογιών συγκεντρώνει όλο και περισσότερο ενδιαφέρον. Η έρευνα στον τομέα αυτό αφορά τόσο σε εφαρμογές με ιατρικό ενδιαφέρον (π.χ. για ανθρώπους με κινητικά προβλήματα), όσο και σε εφαρμογές με πολλές χρήσεις στη καθημερινότητα (π.χ. σύστημα υποβοήθησης κατά την οδήγηση για αποφυγή εμποδίων). Μία ομάδα εφαρμογών BCI που δίνει λύσεις και στις δύο παραπάνω κατηγορίες είναι αυτές που βασίζονται στη Νοερή Κίνηση. Κάθε εφαρμογή BCI περιλαμβάνει την καταγραφή και προεπεξεργασία εγκεφαλικών σημάτων, καθώς και τη χρήση μεθόδων μηχανικής μάθησης με σκοπό την ταξινόμηση των σημάτων για ορισμένες εργασίες. Το κύριο πρόβλημα που έχουν να αντιμετωπίσουν οι ερευνητές είναι η μη στάσιμη φύση των σημάτων Ηλεκτροεγκεφαλογραφήματος (ΗΕΓ ή EEG) που θέτει πολλές προκλήσεις στην επιτυχή προεπεξεργασία και ταξινόμηση των σημάτων. Η παρούσα διπλωματική διερευνά την απόδοση διαφόρων συστημάτων ταξινόμησης σημάτων Ηλεκτροεγκεφαλογραφήματος (EEG), προερχόμενα από ένα δημόσιο σύνολο δεδομένων βασισμένο σε BCI για Νοερή κίνηση. Στο πλαίσιο της εργασίας υλοποιήθηκε ένα πρωτότυπο ολοκληρωμένο σύστημα, σε ενοποιημένο μοντέλο, εκπαιδύσιμο απ' άκρη σ' άκρη, με δύο βασικά συστατικά: μία μέθοδο χωρικού φιλτραρίσματος (CSP) και έναν ταξινομητή βασισμένο σε βαθύ νευρωνικό δίκτυο. Οι παράμετροι του νευρωνικού δικτύου υπολογίζονται άμεσα κατά τη διάρκεια της εκπαίδευσης, με τρόπο ώστε η ταξινόμηση να δημιουργεί χαρακτηριστικά υψηλής διαχωριστικότητας απευθείας από τα σήματα EEG. Η δομή του συστήματος είναι τέτοια ώστε να αντιμετωπίζει τόσο τη χωρική όσο και τη χρονική μεταβλητότητα που υπάρχει εκ φύσεως στο πρόβλημα ταξινόμησης σημάτων EEG. Η προτεινόμενη δομή συγκρίνεται με άλλες διαδεδομένες δομές στο ίδιο σύνολο δεδομένων. Σημείο αναφοράς αποτελεί η σύγκριση με την πρόσφατη αρχιτεκτονική OPTICAL που χρησιμοποιεί κατά βάση CSP και LSTM και δείχνει να υπερέχει σε σχέση με τις υπόλοιπες. Από τα αποτελέσματα ενισχύεται η πεποίθηση ότι το πρόβλημα είναι εν γένει εξαρτώμενο από τον χρήστη. Φαίνεται ωστόσο ότι η προτεινόμενη μεθοδολογία, η οποία επιδεικνύει συγκρίσιμη απόδοση, θα μπορούσε σε μελλοντική έρευνα, δεδομένης της ευελιξίας της ως προς δομή και την παραμετροποίηση, με κατάλληλη βελτιστοποίηση ανά χρήση, να δώσει εξαιρετικά αποτελέσματα.

**A Deep Machine Learning Architecture  
for Filtering and Classification of Motor Imagery EEG Data**

---

*Diploma Thesis*

*Author: Nikos Lytridis*

**Abstract**

The Brain-Computer Interface (BCI) is a scientific field, which with the development of new technologies is gaining more and more interest. Research in this area concerns both applications of medical interest (e.g. for people with mobility problems) and applications with multiple uses in everyday life (e.g. driving assistance system to avoid obstacles). A group of BCI applications that provide solutions to both of the above categories are those based on Motor Imagery. Each BCI application includes the recording and pre-processing of brain signals, as well as the use of machine learning methods in order to classify signals for certain tasks. The main problem that researchers face is the non-stationary nature of electroencephalogram (EEG) signals, which poses many challenges in the successful pre-processing and classification of signals. This diploma thesis investigates the performance of various electroencephalogram (EEG) signal classification systems, derived from a public data set based on BCI for Motor Imagery. As part of the work, an original integrated system was implemented, in a unified model, trainable from end to end, with two basic components: a spatial filtering method (CSP) and a classifier based on a deep neural network. The neural network parameters are adjusted directly during the training, so that the classification creates highly distinguishing features directly from the EEG signals. The structure of the system is such as to deal with both the spatial and temporal variability that exist naturally in the problem of classifying EEG signals. The proposed structure is compared to other common structures on the same data set. A point of reference is the comparison with the recent OPTICAL architecture that basically uses CSP and LSTM and seems to excel over the rest. The results reinforce the belief that the problem is generally user-dependent. It seems, however, that the proposed methodology, which shows comparable performance, could give excellent results in future research, given its flexibility in structure and configuration, with appropriate per-user optimization.

## Ευχαριστίες

Η διπλωματική εργασία με θέμα «*Μια Αρχιτεκτονική Βαθιάς Μηχανικής Μάθησης για Φιλτράρισμα και Ταξινόμηση δεδομένων σε ΗΕΓ Νοερής Κίνησης*» εκπονήθηκε στο πλαίσιο περάτωσης των σπουδών στη Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Πολυτεχνείου Κρήτης. Το συγκεκριμένο θέμα επιλέχθηκε γιατί απ' τη μια καλύπτει επαρκώς επιστημονικά αντικείμενα που διδάσκονται στο πρόγραμμα σπουδών της σχολής, όπως Μηχανική Μάθηση και Ψηφιακή Επεξεργασία Σήματος, αλλά συνδέεται και με θέματα που άπτονται 'ξένων' κλάδων, όπως αυτόν της Ψυχολογίας και της Νευρολογίας. Οπότε, μου έδωσε τη δυνατότητα το θέμα αυτό, να εξετάσω πως με τη χρήση νέων τεχνολογιών μπορούμε να αναλύσουμε και να λύσουμε σύγχρονα προβλήματα σε άλλους κλάδους και με τρόπο που να έχει αντίκτυπο στην καθημερινή ζωή.

Με το θέμα αυτής της διπλωματικής εργασίας, είχα την ευκαιρία, να ασχοληθώ με τον πολύ ενδιαφέροντα τομέα των διεπαφών εγκεφάλου υπολογιστή (BCI) και πιο συγκεκριμένα με την ταξινόμηση σημάτων Ηλεκτροεγκεφαλογραφήματος (EEG), όπου έγινε μελέτη πολλών άρθρων, κυρίως στις διάφορες μεθόδους μηχανικής μάθησης που χρησιμοποιούνται ευρέως για την ταξινόμηση των σημάτων αυτών. Στη συνέχεια, μου έδωσε τη δυνατότητα να φτιάξω απ' το μηδέν ένα Νευρωνικό Δίκτυο, να αξιολογήσω το σύστημα με δημόσια πακέτα δεδομένων EEG και να το συγκρίνω με άλλες δημοφιλείς προσεγγίσεις.

Στο σημείο αυτό θα ήθελα να ευχαριστήσω πρώτα και κύρια την οικογένειά μου, για την αμέριστη συμπαράστασή τους όλα αυτά τα χρόνια στις σπουδές μου. Επίσης, θέλω να ευχαριστήσω τον Αν. Καθ. Μιχάλη Λαγουδάκη για την καθοδήγηση που μου παρείχε όλη αυτή τη περίοδο επιβλέποντας την υλοποίηση της διπλωματικής μου εργασίας. Καθώς και συνολικά το προσωπικό της Σχολής Η.Μ.Μ.Υ του Π.Κ. που όλα αυτά χρόνια ήρθα σε επαφή μαζί του στα αμφιθέατρα και τα εργαστήρια, αποκομίζοντας τα απαραίτητα εφόδια για το επαγγελματικό μου μέλλον. Τέλος, θέλω να ευχαριστήσω όλους αυτούς, φίλους και γνωστούς, που μου χάρισαν ευχάριστες αναμνήσεις και εμπειρίες στα φοιτητικά μου χρόνια.

## Περιεχόμενα

<b>Περίληψη</b>	<b>3</b>
<b>Abstract</b>	<b>4</b>
<b>Ευχαριστίες</b>	<b>5</b>
<b>Περιεχόμενα</b>	<b>6</b>
<b>Κεφάλαιο 1 Εισαγωγή</b>	<b>8</b>
Κ.1.1 Εισαγωγικά	8
Κ.1.2 Συνεισφορά Εργασίας	8
Κ.1.3 Επισκόπηση Εργασίας	9
<b>Κεφάλαιο 2 Προαπαιτούμενα</b>	<b>10</b>
Κ.2.1 Διεπαφή Εγκεφάλου-Υπολογιστή (ΔΕΥ)	10
Κ.2.2 Η Ηλεκτροεγκεφαλογραφία (ΗΕΓ)	11
Κ.2.3 Νοερή Κίνηση (ΝΚ) Motor Imagery (MI)	12
Κ.2.4 Σημειογραφία Πειραμάτων EEG	12
Κ.2.5 Μέθοδοι Προεπεξεργασίας και Ταξινόμησης για EEG	13
Κ.2.6 Η Τεχνική του CSP	15
<b>Κεφάλαιο 3 Το Πρόβλημα</b>	<b>Error! Bookmark not defined.</b>
Κ.3.1 Το πρόβλημα και ο σκοπός	18
Κ.3.2 Το Σύνολο Δεδομένων	18
Κ.3.2.2 Διαχωριστικότητα δεδομένων ανά χρήση	20
Κ.3.3 Σχετική Έρευνα	21
Κ.3.3.1 Ενοποιημένο Νευρωνικό Δίκτυο για Ταξινόμηση EEG	23
Κ.3.3.2 OPTICAL Ταξινομητής	24
<b>Κεφάλαιο 4 Η συνεισφορά μας</b>	<b>27</b>
Κ.4.1 UniNNET	27
Κ.4.1.1 Εκπαίδευση	28
Κ.4.2 Αποτελέσματα	30
<b>Κεφάλαιο 5 Συμπεράσματα</b>	<b>37</b>
Κ.5.1 Συζήτηση	37
Κ.5.2 Μελλοντική δουλειά	39
<b>Βιβλιογραφία</b>	<b>40</b>



# Κεφάλαιο 1 Εισαγωγή

## Κ.1.1 Εισαγωγικά

Το πεδίο Brain-Computer Interface (BCI) είναι ένας πολλά υποσχόμενος κλάδος που τα τελευταία χρόνια συνεχώς εξελίσσεται. Πρόκειται για ένα τεχνολογικό εργαλείο που γεφυρώνει τις αποστάσεις μεταξύ ανθρώπων και μηχανών, αντικαθιστώντας τους παραδοσιακούς τρόπους Επικοινωνίας Ανθρώπου-Υπολογιστή, στην ουσία αξιοποιώντας την Κεντρική Μονάδα Επεξεργασίας που έχει ο άνθρωπος, τον εγκέφαλό του. Ο αρχικός σκοπός στην ανάπτυξη εφαρμογών για BCI ήταν για καθαρά κλινική χρήση, όπως για αποκατάσταση ατόμων μετά από κάποιον τραυματισμό ή ως μέσο επικοινωνίας για ανθρώπους με ψυχικά, ψυχοσωματικά σύνδρομα ή εγκεφαλικές κακώσεις [1][2]. Ωστόσο, τα τελευταία χρόνια με την πρόοδο της τεχνολογίας τα συστήματα BCI μπορούν να απλοποιηθούν σε σχέση με παλαιότερα και να γίνουν πιο οικονομικά και πιο προσιτά, ακόμα και σε υγιείς χρήστες, με διάφορες χρήσεις, όπως για παράδειγμα σε εφαρμογές στον τομέα της ψυχολογίας (π.χ. ως εργαλείο αυτοβελτίωσης, διαχείρισης άγχους, διαταραχών ύπνου, κ.α.) αλλά και πιο γενικά, ως ένα ακόμη πιο hands-free μέσο επικοινωνίας με μία συσκευή [3][4].

Η ανάπτυξη όμως εφαρμογών BCI έχει πολλές προκλήσεις. Η μέχρι τώρα έρευνα δείχνει να έχει καλά αποτελέσματα σε κλινικά ελεγχόμενο περιβάλλον ή σε εργαστηριακό περιβάλλον, όπου μπορεί κανείς να παρακολουθεί και να οριοθετήσει τις παραμέτρους του προβλήματος, ωστόσο για εφαρμογές στην καθημερινότητα εισάγονται πολλές παράμετροι με απρόβλεπτη συμπεριφορά. Οι περισσότερες εφαρμογές για καθημερινή χρήση βασίζονται σε σήματα Ηλεκτροεγκεφαλογραφήματος (HEΓ ή EEG), επειδή είναι μία οικονομική μέθοδος καταγραφής που μπορεί να πραγματοποιηθεί με σχετικά προσβάσιμο εξοπλισμό και η διαδικασία απόκτησης των δεδομένων μπορεί να γίνει εύκολα και γρήγορα. Ωστόσο, τα σήματα EEG, από τη φύση τους, παρουσιάζουν μία μη στατική συμπεριφορά, επηρεάζοντας έτσι την απόδοση της ταξινόμησης και ως εκ τούτου την αποτελεσματικότητα του συστήματος BCI συνολικά [5][6][7]. Αυτή η συμπεριφορά οφείλεται τόσο σε ενδογενείς παράγοντες που αφορούν στη λειτουργία του εγκέφαλου (την προσοχή, την κούραση του χρήστη), όσο και σε εξωγενείς παράγοντες που αφορούν στο περιβάλλον και την αλληλεπίδραση του χρήστη με αυτό.

## Κ.1.2 Συνεισφορά Εργασίας

Στην παρούσα διπλωματική εργασία, διερευνώνται διάφορες προσεγγίσεις που αφορούν εφαρμογές BCI βασισμένες στη Νοερή Κίνηση και υπόσχονται να περιορίσουν ή να αντιμετωπίσουν τα μειονεκτήματα της μη στάσιμης φύσης των σημάτων EEG. Ως εκ τούτου, μελετήσαμε σε βάθος την προσέγγιση που προτείνεται στο [8] και δημιουργούμε από μηδενική βάση μία απλοποιημένη εκδοχή της προτεινόμενης αρχιτεκτονικής, που βασίζεται σε CSP και Βαθύ Νευρωνικό Δίκτυο. Την δομή αυτή τη συγκρίνουμε έπειτα με τα αποτελέσματα πρόσφατης εργασίας [9] που



χρησιμοποιεί καινοτόμες μεθόδους μηχανικής μάθησης. Η σύγκριση των παραπάνω μεθόδων έγινε μαζί με άλλες πάνω στο ίδιο σύνολο δεδομένων [10] που αφορά σε δεδομένα που καταγράφηκαν από 52 χρήστες για ανάπτυξη και έρευνα εφαρμογών BCI βασισμένες σε Νοερή Κίνηση. Τα αποτελέσματα δείχνουν πως μπορεί να υπάρξουν συστήματα με ικανοποιητική απόδοση ταξινόμησης και πως υπάρχουν σήμερα τα εργαλεία, ώστε να αντιμετωπιστεί η μη στατική φύση των σημάτων και μάλιστα σε εφαρμογές πραγματικού χρόνου, ωστόσο η αντιμετώπιση αυτή, σύμφωνα με την μέχρι τώρα γνώση μας, περιορίζεται στον εκάστοτε χρήστη, χωρίς να υπάρχει ως τώρα κάποια καθολική προσέγγιση.

### Κ.1.3 Επισκόπηση Εργασίας

Παρακάτω, θα παρουσιάσουμε συνοπτικά τη δομή των κεφαλαίων, πέρα από το εισαγωγικό Κεφάλαιο 1, ώστε να γίνει πιο εύκολο στον αναγνώστη να ακολουθήσει την ανάπτυξη του θέματος στην συγκεκριμένη εργασία.

Στο Κεφάλαιο 2, παραθέτουμε κάποιες προαπαιτούμενες γνώσεις. Καθότι το θέμα συνδυάζει διαφορετικούς επιστημονικούς κλάδους, μπορεί να υπάρχουν ορισμοί και ορολογίες που είναι βασικές κατά τη μελέτη της εργασίας. Η επιλογή των γνώσεων παρατίθεται με τέτοιο τρόπο, ώστε να είναι πιο ευανάγνωστο το κείμενο, κυρίως για κάποιον από τον κλάδο της πληροφορικής, ώστε να συμπληρώσει τυχόν ελλείψεις, ωστόσο ελπίζουμε ότι είναι με απλό τρόπο γραμμένο, ώστε οποιοσδήποτε με ενδιαφέρον στο θέμα να μπορεί να διαβάσει αυτή την εργασία.

Στο Κεφάλαιο 3, παρουσιάζουμε τις προκλήσεις στην ανάπτυξη εφαρμογών BCI βασισμένες στη Νοερή Κίνηση. Αναλύουμε το σύνολο δεδομένων που χρησιμοποιήθηκε σ' αυτή την εργασία, δίνοντας και απαραίτητες πληροφορίες τόσο για το πείραμα, όσο και για την αξιολόγηση των δεδομένων. Έπειτα, παρουσιάζουμε κάποιες από τις πιο δημοφιλείς μεθόδους για ταξινόμηση σημάτων EEG, καθώς και τη σχετική έρευνα που αφορά στην αντιμετώπιση της μη στάσιμης φύσης των σημάτων.

Στο Κεφάλαιο 4, αναλύουμε την μεθοδολογία με την οποία αναπτύξαμε την αρχιτεκτονική στα πλαίσια της εργασίας. Παρουσιάζουμε τον λόγο που επιλέξαμε τη συγκεκριμένη δομή και τις παραμέτρους της, καθώς και το πως εκπαιδεύουμε συνολικά το σύστημα. Παρουσιάζουμε επίσης και τα αποτελέσματα από τη σύγκριση της δομής που υλοποιήθηκε σε σχέση με άλλες.

Τέλος, στο Κεφάλαιο 5, συνοψίζουμε τα συμπεράσματα συνολικά όλης της εργασίας, όπως αυτά προκύπτουν με βάση τα αποτελέσματα. Επίσης προτείνουμε μελλοντικές εργασίες πάνω στο θέμα, τι προεκτάσεις μπορεί να έχει, κ.α.

## Κεφάλαιο 2 Προαπαιτούμενα

Σε αυτό το κεφάλαιο θα γίνει μια προσπάθεια να καλυφθούν συνοπτικά κάποιες βασικές γνώσεις γύρω από τα αντικείμενα που σχετίζονται με το θέμα της συγκεκριμένης εργασίας. Συγκεκριμένα, θα γίνει μια σύντομη περιγραφή των ορισμών και των λέξεων-κλειδιών που θα χρησιμοποιηθούν παρακάτω στην εργασία. Στόχος του κεφαλαίου είναι να βοηθήσει τον αναγνώστη να προχωρήσει ομαλά και με δομημένο τρόπο στα επόμενα κεφάλαια, χωρίς βασικές ελλείψεις σε θεωρητικό επίπεδο. Επειδή το θέμα της εργασίας αποτελεί σημείο συνάντησης διαφορετικών επιστημών, ελπίζουμε αυτό το κεφάλαιο να παρέχει το επαρκές υπόβαθρο, ώστε να κάνει την εργασία αυτή πιο προσιτή στο ευρύτερο κοινό.

### Κ.2.1 Διεπαφή Εγκεφάλου-Υπολογιστή (ΔΕΥ)

Η Διεπαφή Εγκεφάλου-Υπολογιστή (ΔΕΥ) ή Brain-Computer Interface (BCI) είναι ένας άμεσος τρόπος για την επικοινωνία μεταξύ του εγκεφάλου ενός ανθρώπου και μιας εξωτερικής συσκευής. Στην ουσία, είναι ένας τρόπος να μπορούν οι χρήστες να ενεργούν στο περιβάλλον τους, χρησιμοποιώντας μόνο την δραστηριότητα του εγκεφάλου τους, χωρίς την χρήση νεύρων ή μυών.

Στο πεδίο της έρευνας και ανάπτυξης, οι ΔΕΥ ή BCI στοχεύουν κυρίως στην αποκατάσταση της βλάβης της ακοής, της όρασης ή/και της κίνησης. Οι τρεις βασικές κατηγορίες στις οποίες μπορούν να χωριστούν οι εφαρμογές BCI είναι οι επεμβατικές, οι μερικώς επεμβατικές και οι μη επεμβατικές.

Η επεμβατική έρευνα σε BCI έχει στοχεύσει στην αποκατάσταση των προβλημάτων στην όραση και στην παροχή λειτουργικότητας σε άτομα με παράλυση. Οι επεμβατικές διατάξεις BCI εμφυτεύονται απευθείας στο εσωτερικό του εγκεφάλου με νευροχειρουργική επέμβαση. Το εμφύτευμα-τσιπ τοποθετείται απευθείας μέσα στον εγκέφαλο σε τμήματα που αποκαλούνται γκρίζα ύλη. Η γκρίζα ύλη περιέχει τα περισσότερα νευρωνικά κύτταρα του εγκεφάλου και περιλαμβάνει περιοχές που εμπλέκονται στον έλεγχο των μυών και την αισθητική αντίληψη, όπως η όραση και η ακοή, η μνήμη, τα συναισθήματα, ο λόγος, η λήψη αποφάσεων και ο αυτοέλεγχος. Για τον λόγο αυτό, οι επεμβατικές μέθοδοι παράγουν σήματα υψηλότερης ποιότητας στις συσκευές BCI, αλλά έχουν το μειονέκτημα της χειρουργικής επέμβασης, καθώς και την πιθανότητα το σώμα να αντιδρά στο εμφύτευμα, προκαλώντας τελικά εξασθένηση στο σήμα.

Οι μερικώς επεμβατικές συσκευές BCI εμφυτεύονται μέσα στο κρανίο, αλλά έξω από τον εγκέφαλο και σίγουρα όχι μέσα στην γκρίζα ύλη. Παράγουν σήματα καλύτερης ανάλυσης από τις μη επεμβατικές BCI, όπου ο οστικός ιστός του κρανίου παραμορφώνει τα σήματα. Επίσης, μια μερικώς επεμβατική διάταξη έχει μικρότερο χειρουργικό κίνδυνο για τον εγκέφαλο, απ' ό,τι οι πλήρως επεμβατικές BCI. Η κύρια μέθοδος μερικώς επεμβατικής τεχνολογίας BCI είναι η Ηλεκτροκορτικογραφία (ECoG). Η ECoG είναι μια πολύ ελπιδοφόρα ενδιάμεση μέθοδος BCI, επειδή έχει υψηλότερη χωρική ανάλυση, καλύτερη αναλογία σήματος προς θόρυβο, μεγαλύτερο εύρος συχνότητας και λιγότερες απαιτήσεις εκπαίδευσης από ότι το

Ηλεκτροεγκεφαλογράφημα (EEG), όπου γίνεται η καταγραφή έξω από το κρανίο. Ταυτόχρονα έχει χαμηλότερες τεχνικές δυσκολίες, χαμηλότερο κλινικό κίνδυνο, και πιθανώς ανώτερη μακροπρόθεσμη σταθερότητα σε σχέση με τις πλήρως επεμβατικές μεθόδους. Αυτά τα χαρακτηριστικά, καθώς και οι πρόσφατες ενδείξεις για υψηλό επίπεδο ελέγχου με ελάχιστες απαιτήσεις κατάρτισης, δείχνουν δυνατότητες για εφαρμογές στο πραγματικό κόσμο σε άτομα με κινητικές δυσκολίες.

Η μεγάλη πλειοψηφία των δημοσιευμένων εργασιών BCI περιλαμβάνει μη επεμβατικές μεθόδους με βάση το Ηλεκτροεγκεφαλογράφημα (EEG). Οι μη επεμβατικές τεχνολογίες και οι διεπαφές με βάση το Ηλεκτροεγκεφαλογράφημα (EEG) έχουν χρησιμοποιηθεί για μια ευρύτατη ποικιλία εφαρμογών.

#### Κ.2.2 Η Ηλεκτροεγκεφαλογραφία (ΗΕΓ)

Η ηλεκτροεγκεφαλογραφία (ΗΕΓ) ή Electroencephalography (EEG) είναι η πιο μελετημένη μη επεμβατική διεπαφή, κυρίως λόγω της καλής χρονικής ανάλυσης, της ευκολίας χρήσης, της φορητότητας και του χαμηλού κόστους εγκατάστασής της. Η τεχνολογία αυτή ωστόσο είναι κάπως ευαίσθητη στον θόρυβο.

Η ηλεκτροεγκεφαλογραφία (ΗΕΓ) είναι μια ηλεκτροφυσιολογική μέθοδος παρακολούθησης και καταγραφής της ηλεκτρικής δραστηριότητας του εγκεφάλου. Γίνεται με τοποθέτηση ηλεκτροδίων κατά μήκος του τριχωτού της κεφαλής, αν και μερικές φορές χρησιμοποιούνται διηθητικά ηλεκτρόδια, όπως στην ηλεκτροκορτικογραφία (ECoG). Η EEG μετρά τις διακυμάνσεις της τάσης που προκύπτουν από το ιοντικό ρεύμα μέσα στους νευρώνες του εγκεφάλου.


Σε κλινικό πλαίσιο, η EEG αναφέρεται στην καταγραφή της αυθόρμητης ηλεκτρικής δραστηριότητας του εγκεφάλου σε μια χρονική περίοδο, όπως καταγράφεται από πολλαπλά ηλεκτρόδια που τοποθετούνται στο τριχωτό της κεφαλής. Οι διαγνωστικές εφαρμογές επικεντρώνονται γενικά, είτε στις δυνατότητες που σχετίζονται με γεγονότα (Event-Related Potentials, ERPs), είτε στο φασματικό περιεχόμενο των σημάτων EEG. Οι πρώτες διερευνούν τις πιθανές χρονικές διακυμάνσεις που σχετίζονται με ένα γεγονός, όπως η αντίδραση σε κάποιο ερέθισμα ή το πάτημα ενός κουμπιού. Οι δεύτερες αναλύουν τον τύπο των νευρωνικών ταλαντώσεων (που γενικά ονομάζονται «κύματα του εγκεφάλου») που μπορούν να παρατηρηθούν απ' τα σήματα EEG στο πεδίο των συχνοτήτων.

Οι εφαρμογές EEG που σχετίζονται με γεγονότα (ERP), περιλαμβάνουν κατά μέσο όρο τη δραστηριότητα των σημάτων EEG, που είναι χρονικά εξαρτώμενα από την παρουσίαση ενός ερεθίσματος κάποιου είδους (οπτικό, σωματοαισθητικό ή ακουστικό). Δηλαδή, οι δυνατότητες που σχετίζονται με γεγονότα (ERPs) αναφέρονται σε μέσες αποκρίσεις σημάτων EEG που είναι χρονικά εξαρτώμενες από μια πολύπλοκη επεξεργασία ερεθισμάτων. Το EEG και η σχετική μελέτη των ERP χρησιμοποιούνται ευρέως στη νευροεπιστήμη, τη γνωστική επιστήμη, τη γνωστική ψυχολογία. Συγκεκριμένα, για τα προβλήματα ταξινόμησης σημάτων EEG η έρευνα σχετικά με τα ERPs περιλαμβάνει την αναγνώριση προτύπων στα σήματα για συγκεκριμένα

ερεθίσματα (π.χ. οπτικά), όπου εκεί υπάρχει και απότομη αλλαγή της κυματομορφής (spike).

### Κ.2.3 Νοερή Κίνηση (NK) Motor Imagery (MI)

Μια άλλη πολύ διαδεδομένη τεχνική στα πειράματα με EEG και όχι μόνο, είναι η Νοερή Κίνηση. Η Νοερή Κίνηση είναι μια νοητική διαδικασία κατά την οποία το άτομο προσομοιώνει μία κινητική ενεργεία στο μυαλό του, χωρίς όμως να εκτελεί την κίνηση αυτή. Χρησιμοποιείται σαν τεχνική, κυρίως στον κλάδο των Νευροεπιστημών και της Ψυχολογίας, και συνήθως μελετά τη δραστηριότητα των σημάτων EEG, σε συνδυασμό με δεδομένα ηλεκτρομυογραφήματος (ΗΜΓ ή EMG) και πρόκειται για ηλεκτρικά σήματα που παράγονται από κινητικούς νευρώνες των μυών. Στο πλαίσιο της συγκεκριμένης εργασίας μας ενδιαφέρει η χρήση της τεχνικής αυτής για πειράματα ταξινόμησης EEG. Πρόκειται για BCI, στις οποίες ο τελικός σκοπός είναι η ανάπτυξη εφαρμογών, όπου ο χρήστης προσομοιώνει κάποια κινητική διαδικασία, π.χ. κίνηση χεριού, η οποία μεταδίδεται από τον εγκέφαλό του, π.χ. σε κάποιον ρομποτικό βραχίονα. Στην εικόνα 2.1 φαίνεται σχηματικά ένα απλό BCI σύστημα.



Εικόνα 2.1 Ένα απλό σύστημα BCI [24]

#### Κ.2.4 Σημειογραφία Πειραμάτων EEG

Εδώ θέλουμε συνοπτικά να δώσουμε τη σημειογραφία για κάποιες λέξεις-κλειδιά που χρησιμοποιούνται σε πειράματα καταγραφής EEG. Περαιτέρω ανάλυση των πειραμάτων αυτών θα γίνει σε παρακάτω κεφάλαιο.

*Συνεδρία (session)*: Σε ένα κλασικό πείραμα BCI για ταξινόμηση σημάτων EEG, ο χρήστης καλείται να εκτελέσει διαφορετικές εργασίες, καθώς τα σήματα του εγκεφάλου καταγράφονται και αποθηκεύονται μαζί με ετικέτες για τις κλάσεις στις οποίες αντιστοιχούν. Τα καταγεγραμμένα σήματα χρησιμεύουν ως πακέτα δεδομένων (datasets) για την εκπαίδευση των μεθόδων μηχανικής μάθησης στα συστήματα BCI. Η διαδικασία αυτή καλείται και εκπαιδευτική συνεδρία.

*Δοκιμή (trial)*: Κάθε εκπαιδευτική συνεδρία διεξάγεται με δοκιμές, δηλαδή εργασίες που κάνει ο χρήστης βάσει οδηγιών. Στο σύνολο δεδομένων που χρησιμοποιούμε σε αυτή την εργασία, το οποίο έχει δεδομένα για εργασίες σε Νοερή Κίνηση, κάθε συνεδρία έχει 200 δοκιμές (100 για κάθε κλάση), οπότε κάθε δοκιμή περιλαμβάνει την καταγραφή των σημάτων EEG την ώρα που ο χρήστης εκτελεί μία εργασία Νοερής Κίνησης.

#### Κ.2.5 Μέθοδοι Προεπεξεργασίας και Ταξινόμησης για EEG

Εδώ θα παρουσιαστούν σύντομα οι βασικές μέθοδοι προεπεξεργασίας σημάτων στα σήματα EEG, καθώς και οι πιο βασικές δομές μηχανικής μάθησης που χρησιμοποιήθηκαν στη συγκεκριμένη διπλωματική εργασία, αλλά και στις υπόλοιπες προσεγγίσεις, όπως αυτές παρουσιάζονται στη σχετική βιβλιογραφία. Σε επόμενα κεφάλαια θα γίνει συνοπτική αναφορά μερικών από τις μεθόδους που χρησιμοποιήσαμε ως σημείο αναφοράς για να τις συγκρίνουμε με τη δική μας υλοποίηση.

##### ➤ Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines, SVM)

Στην μηχανική μάθηση οι μηχανές διανυσμάτων υποστήριξης (SVM) είναι μοντέλο μάθησης με επιτήρηση που χρησιμοποιείται τόσο σε προβλήματα ταξινόμησης, όσο και σε προβλήματα παλινδρόμησης. Η κατηγοριοποίηση των δεδομένων στηρίζεται στην εύρεση ενός βέλτιστου υπερεπιπέδου που διαχωρίζει τα δεδομένα, δημιουργώντας το μέγιστο περιθώριο. Στην περίπτωση που ο γραμμικός διαχωρισμός είναι αδύνατος, γίνεται χρήση κατάλληλων απεικονίσεων που μεταφέρουν το σύνολο των δεδομένων σε μεγαλύτερη διάσταση, ώστε να επιτευχθεί τελικά ο διαχωρισμός τους. Η ικανότητα γενίκευσης της χρήσης των SVM σε μη γραμμικά δεδομένα στηρίζεται στο τέχνασμα του πυρήνα (kernel trick). Κάθε μηχανή διανυσμάτων

υποστήριξης είναι ένας δυαδικός ταξινομητής, έχει δηλαδή τη δυνατότητα κατηγοριοποίησης σε δύο κλάσεις. Εάν οι κλάσεις είναι περισσότερες, τότε κρίνεται απαραίτητη η χρήση περισσότερων μηχανών διανυσμάτων υποστήριξης.

➤ Ανάλυση Γραμμικής Διάκρισης (Linear Discriminant Analysis, LDA)

Η Ανάλυση Γραμμικής Διάκρισης (Linear Discriminant Analysis, LDA) είναι είναι μια μέθοδος μετασχηματισμού δεδομένων που ανήκουν σε κατηγορίες (κλάσεις), με σκοπό το βέλτιστο διαχωρισμό των κλάσεων και ταυτόχρονα την ελάττωση των διαστάσεων των δεδομένων. Η μέθοδος LDA είναι αποτελεσματικότερη στην περίπτωση διαχωρισμού δύο κλάσεων, με μεταβλητές των οποίων οι τιμές ακολουθούν την κανονική κατανομή. Η LDA χρησιμοποιείται κυρίως στο πεδίο της εποπτευόμενης αναγνώρισης προτύπων, αφενός λόγω της δραστικής ελάττωσης στις διαστάσεις των δεδομένων και αφετέρου ως ένας από τους βασικούς ταξινομητές για την κατηγοριοποίηση των δεδομένων.

➤ Τεχνητό Νευρωνικό Δίκτυο (Artificial Neural Network, ANN)

Τα τεχνητά νευρωνικά δίκτυα (ANN) είναι υπολογιστικά συστήματα εμπνευσμένα από τα βιολογικά δίκτυα νευρικών κυττάρων του εγκεφάλου. Αυτά τα συστήματα «μαθαίνουν» να κάνουν πολύπλοκες εργασίες, ουσιαστικά δηλαδή προοδευτικά να προσαρμόζονται στα δεδομένα εισόδου, βελτιστοποιώντας την απόδοσή τους ως προς την απόκριση του δικτύου (ταξινόμηση, εξαγωγή πληροφορίας, κ.α). Αυτό γίνεται με την επαναλαμβανόμενη εξέταση παραδειγμάτων, γενικά χωρίς προγραμματισμό συγκεκριμένων εργασιών, με τρόπο τέτοιο ώστε το δίκτυο να εκπαιδεύεται σε ένα σύνολο δεδομένων. Εν συνεχεία, το δίκτυο χρησιμοποιεί τα αποτελέσματα εφαρμόζοντας την «γνώση» σε άλλο άγνωστο σύνολο δεδομένων. Είναι σημαντικό ότι η διαδικασία αυτή δε χρειάζεται κάποια εκ των προτέρων γνώση της φύσης των χαρακτηριστικών στα οποία υπάρχει η σημαντική πληροφορία. Τα νευρωνικά δίκτυα εξαγάουν το δικό τους σύνολο σχετικών χαρακτηριστικών από το σύνολο δεδομένων στο οποίο εκπαιδεύονται. Το πλεονέκτημα αυτό είναι εξαιρετικά σημαντικό για τις εφαρμογές σε BCI, όπου η συμπεριφορά των δεδομένων (των σημάτων EEG) είναι άγνωστη για συγκεκριμένες εργασίες και ως εκ τούτου άγνωστα τα χαρακτηριστικά που ψάχνουμε.

Γενικά, ένα νευρωνικό δίκτυο είναι μια συλλογή από συνδεδεμένες μονάδες ή κόμβους που ονομάζονται τεχνητοί νευρώνες (μια απλοποιημένη εκδοχή βιολογικών νευρώνων). Κάθε σύνδεση (μια απλοποιημένη εκδοχή συνάψεως) μεταξύ των τεχνητών νευρώνων μπορεί να μεταδώσει ένα σήμα. Ο τεχνητός νευρώνας που λαμβάνει το σήμα μπορεί να το επεξεργαστεί και στη συνέχεια να το μεταδώσει στους τεχνητούς νευρώνες που συνδέονται με αυτόν.

Οι τεχνητοί νευρώνες και συγκεκριμένα οι συνάψεις τους έχουν συνήθως ένα βάρος που προσαρμόζεται κατά τη διαδικασία της μάθησης. Το βάρος αυξάνει ή μειώνει την ισχύ του σήματος μιας σύναψης. Οι τεχνητοί νευρώνες έχουν ένα κατώφλι (συνάρτηση ενεργοποίησης), τέτοιο ώστε, μόνο αν το εισερχόμενο σήμα υπερβαίνει το κατώφλι, να αποστέλλεται. Γενικά, το νευρωνικό δίκτυο οργανώνεται σε επίπεδα. Τα διαφορετικά επίπεδα μπορούν να εκτελούν διαφορετικά είδη μετασχηματισμών στις εισόδους και εξόδους τους, ανάλογα με τη συνάρτηση ενεργοποίησής τους. Τα σήματα ταξιδεύουν από το πρώτο επίπεδο (είσοδος) έως το τελευταίο επίπεδο (έξοδος), διασχίζοντας τα ενδιάμεσα κρυφά επίπεδα.

- Διαρκείς Μονάδες Βραχυπρόθεσμης Μνήμης (Long Short-Term Memory Units, LSTM)

Τα LSTMs είναι υποκατηγορία των αναδρομικών νευρωνικών δικτύων (Recurrent Neural Networks, RNN) στη Βαθιά Μάθηση (Deep Learning), και, σε αντίθεση με τα παραδοσιακά νευρωνικά δίκτυα με εμπρόσθια τροφοδότηση (feedforward NN), τα LSTM έχουν διασυνδέσεις νευρώνων και με οπίσθια τροφοδότηση. Στη βασική τους λειτουργία κάνουν χρήση συγκεκριμένων πυλών. Οι πύλες αυτές λειτουργούν με βάση τα σήματα που λαμβάνουν και, παρόμοια με τους νευρώνες ενός νευρωνικού δικτύου, εμποδίζουν ή αφήνουν να περάσουν πληροφορίες, βάσει της σημασίας τους, τις οποίες φιλτράρουν με ένα δικό τους σύνολο βαρών. Τα βάρη αυτά, όπως και τα βάρη που προσαρμόζουν τις κρυφές καταστάσεις και τις καταστάσεις εισόδου, μεταβάλλονται μέσω της διαδικασίας της εκπαίδευσης των αναδρομικών νευρωνικών δικτύων. Πράγμα που σημαίνει, ότι τα κελιά μαθαίνουν πότε να επιτρέψουν σε μία πληροφορία να περάσει, πότε να την εμποδίσουν ή πότε να την διαγράψουν μέσω της επαναληπτικής διαδικασίας των προβλέψεων, της οπισθοδιάδοσης σφάλματος και της ενημέρωσης βαρών μέσω του αλγορίθμου απότομης καθόδου (gradient descent). Ως εκ τούτου, μπορούν να διαχειριστούν πληροφορία και από ολόκληρες ακολουθίες δεδομένων, όπου έχουμε φαινόμενα χρονοσειρών ή γενικότερα σειριακή ροή δεδομένων, όπως ομιλία ή βίντεο. Για τον λόγο αυτό, η χρήση των LSTMs είναι πολύ διαδεδομένη μέθοδος για προβλήματα αναγνώρισης χειρόγραφου κειμένου, αναγνώριση ομιλίας, κ.α.

## Κ.2.6 Η Τεχνική του CSP

Για λόγους σαφήνειας, αυτή η υποενότητα περιγράφει εν συντομία την τεχνική Common Spatial Patterns (CSP), η οποία είναι επίσης απαραίτητη για την ακριβή περιγραφή της μεθοδολογίας αναφοράς που ακολουθήσαμε στο [8] και πρωταγωνιστεί επίσης σαν μία από τις πιο δημοφιλείς τεχνικές για προβλήματα και εφαρμογές BCI.

Οι εγγραφές EEG οργανώνονται σε συνεδρίες και κάθε συνεδρία αποτελείται από διάφορες δοκιμές. Ο στόχος ενός συστήματος ταξινόμησης σημάτων EEG είναι να ταξινομή τις δοκιμές σε έναν δεδομένο αριθμό κλάσεων. Το CSP είναι μια ευρέως χρησιμοποιούμενη τεχνική προεπεξεργασίας σημάτων EEG για την αύξηση της διαχωρισιμότητας των δοκιμών διαφορετικών κλάσεων. Κάθε δοκιμή σε μια συνεδρία θα πρέπει να είναι ένα σήμα σε μορφή πίνακα ως εξής:

$$X_{c,i} \in R^{N \times T}$$

όπου ο δείκτης  $c$  υποδηλώνει την κλάση της δοκιμής, ο δείκτης  $i$  είναι ο αριθμός δοκιμής που ανήκει στην κλάση  $c$ ,  $N$  είναι ο συνολικός αριθμός των καναλιών EEG και το  $T$  αντιπροσωπεύει τον αριθμό των δειγμάτων στην δοκιμή. Στα προβλήματα δυαδικής ταξινόμησης, η τεχνική CSP αυξάνει τη διαχωρισιμότητα μεταξύ κλάσεων, προσπαθώντας να μεγιστοποιήσει τη μέση διασπορά μιας κλάσης και ταυτόχρονα να ελαχιστοποιήσει τη μέση διασπορά της άλλης. Η μέση διασπορά της κλάσης  $c$  μπορεί να υπολογιστεί ως εξής:

$$\overline{P}_C = \frac{1}{n_c} \sum_{i=1}^{n_c} w^T X_{c,i} X_{c,i}^T w \quad (1)$$

όπου το διάνυσμα  $w \in R^N$  προβάλει το  $X_{c,i}$  σε έναν χώρο  $N$ -διαστάσεων και  $n_c$  είναι ο αριθμός των δοκιμών που ανήκουν στην  $c$ -οστή κλάση. Έστω ότι

$$R_{c,i} = \frac{X_{c,i} X_{c,i}^T}{X_{c,i} X_{c,i}^T} \quad \text{και} \quad \overline{R}_c = \frac{1}{n_c} \sum_{i=1}^{n_c} R_{c,i}$$

$$\overline{P}_c = w^T \overline{R}_c w$$

είναι ο πίνακας συνδιασποράς της δοκιμής  $X_{c,i}$  και η μέση συνάρτηση συνδιασποράς της κλάσης  $c$ , αντίστοιχα. Στη συνέχεια, η σχέση (1) μπορεί να ξαναγραφεί ως

Τότε, η τεχνική CSP αυξάνει την διαχωρισιμότητα μεταξύ κλάσεων μέσω της εκτίμησης του διανύσματος προβολής  $w^*$  με την επίλυση του ακόλουθου προβλήματος.

$$w^* = \underset{w}{\operatorname{argmax}} \frac{w^T \overline{R}_1 w}{w^T \overline{R}_2 w} \quad (2)$$

Το πρόβλημα (2) είναι ένα τυπικό πρόβλημα ιδιοτιμής και το  $w^*$  είναι ίσο με το ιδιοδιάνυσμα που αντιστοιχεί στη μεγαλύτερη ιδιοτιμή του  $\underline{R}_1 / \underline{R}_2$ .




Το CSP φίλτρο,  $\mathbf{W}$ , είναι ένας πίνακας, ο οποίος κατασκευάζεται με τη χρήση  $M = 2m$  ( $M \leq N$ ) ιδιοδιανυσμάτων που αντιστοιχούν στις  $m$  μεγαλύτερες και  $m$  μικρότερες ιδιοτιμές του  $\underline{R}_1/\underline{R}_2$ , π.χ.,

$$\mathbf{W} = [\mathbf{w}_1, \dots, \mathbf{w}_m, \mathbf{w}_{N-m+1}, \mathbf{w}_N]$$

Κάθε δοκιμή φιλτράρεται χωρικά από το  $Y_{c,i} = \mathbf{W}X_{c,i}$  και τελικά αντιπροσωπεύεται από ένα διάνυσμα χαρακτηριστικών  $f_{c,i}$  της ακόλουθης μορφής:

$$f_{c,i} = \log \left[ \frac{\text{var}(Y_{c,i}^1)}{\sum_{j=1}^M \text{var}(Y_{c,i}^j)} \dots \frac{\text{var}(Y_{c,i}^M)}{\sum_{j=1}^M \text{var}(Y_{c,i}^j)} \right], \quad (3)$$

όπου  $Y_{c,i}^j$  αντιπροσωπεύει την  $j$ -οστή σειρά  $Y_{c,i}$ . Το διάνυσμα χαρακτηριστικών  $f_{c,i}$  χρησιμοποιείται στην προσέγγιση [8] που χρησιμοποιούμε για την εκπαίδευση του νευρωνικού δικτύου.



Εικόνα 2.2 Σχηματική απεικόνιση της επίδρασης του CSP [25]

## Κεφάλαιο 3 Το Πρόβλημα

### Κ.3.1 Το πρόβλημα και ο σκοπός

Η «Νοερή Κίνηση» (NK) (Motor Imagery, MI) χρησιμοποιείται ευρέως ως διαδικασία σε πολλές εφαρμογές BCI. Στην ουσία, πρόκειται για την καταγραφή των δεδομένων EEG την ώρα που ο χρήστης φαντάζεται μία κίνηση, όμως χωρίς παράλληλα να την εκτελεί. Το ζήτημα εδώ είναι ότι παρατηρούνται πολλές αποκλίσεις στην απόδοση ταξινόμησης των EEG σε κλάσεις που αντιστοιχούν σε διαφορετικές κινήσεις και μεταξύ των συνεδριών για ένα χρήστη και μεταξύ διαφορετικών χρηστών. Αυτό συμβαίνει λόγω της φύσης και της βιολογικής κατασκευής του εγκεφάλου, αφού αυτός δε βρίσκεται πάντα στην ίδια κατάσταση. Όπως προκύπτει και από τη βιβλιογραφία, η διαφορά στην απόκριση των σημάτων του εγκεφάλου, ανάλογα με την κατάσταση και ανάλογα με τον χρήστη, σχετίζεται με το φαινόμενο της Χρονικής Μεταβλητότητας (Temporal Variability). Η χρονική μεταβλητότητα δείχνει να επηρεάζεται τόσο από εξωγενείς παράγοντες, που σχετίζονται με το περιβάλλον στο οποίο βρίσκεται ο χρήστης, όσο και από ενδογενείς που έχουν να κάνουν με την κούραση ή την συγκέντρωση του χρήστη τη δεδομένη στιγμή [11].


Για τους παραπάνω λόγους, οι BCI βασισμένες σε NK (MI-BCI) έχουν συγκεντρώσει τεράστιο ενδιαφέρον το τελευταίο διάστημα. Ένα σύστημα BCI βασισμένο σε NK παρέχει στον χρήστη μια απευθείας επικοινωνία, χωρίς την ανάγκη για κίνηση των άκρων ή την αντίδραση σε εξωτερικό ερέθισμα, όπως άλλα συστήματα BCI βασισμένα σε ERPs. Δηλαδή, στη χρήση MI-BCI η εγκεφαλική δραστηριότητα καταγράφεται, όπως αυτή επάγεται, αυτόνομα, και όχι όπως αυτή αντιδρά ή προκαλείται από εξωτερικούς παράγοντες. Αυτό το γεγονός σημαίνει ότι σε MI-BCI τα χαρακτηριστικά που ψάχνουμε επηρεάζονται λιγότερο απ' τους εξωγενείς παράγοντες.

Ωστόσο, δε μπορούμε να πούμε ότι δεν υπάρχει χρονική μεταβλητότητα. Το βασικό θέμα που απασχολεί την έρευνα είναι η μεταφορά «γνώσης» από χρήστη σε χρήστη (π.χ. ένας αλγόριθμος εκπαίδευσης ανεξάρτητος και καθολικός, για κάθε πιθανό χρήστη). Για να επιτευχθεί αυτό, είναι σημαντικό να γίνουν βήματα προόδου στη κατανόηση των αιτιών και στις διακυμάνσεις της απόδοσης μεταξύ διαφόρων χρηστών. Στην έρευνα υπάρχουν διάφορες προσεγγίσεις, ώστε να προσομοιώσουν στα πειράματα καταστάσεις περιβάλλοντος με πραγματικές συνθήκες, όπως π.χ. με χρήση «κατάστασης ηρεμίας» ή με την προσθήκη θορύβου στα σύνολα δεδομένων προς ταξινόμηση, όπως και σε αυτό που χρησιμοποιήθηκε σε αυτή την εργασία και αναλύεται παρακάτω [10].

### Κ.3.2 Το Σύνολο Δεδομένων

Στο συγκεκριμένο dataset [10] έγινε καταγραφή EEG και EMG ταυτόχρονα για δύο (2) κλάσεις, αριστερό ή δεξί χέρι (με 100 ή 120 δοκιμές για κάθε κλάση) σε 52 υγιείς χρήστες, 19 εκ των οποίων ήταν γένος θηλυκού. Είναι ένα δημόσιο dataset που

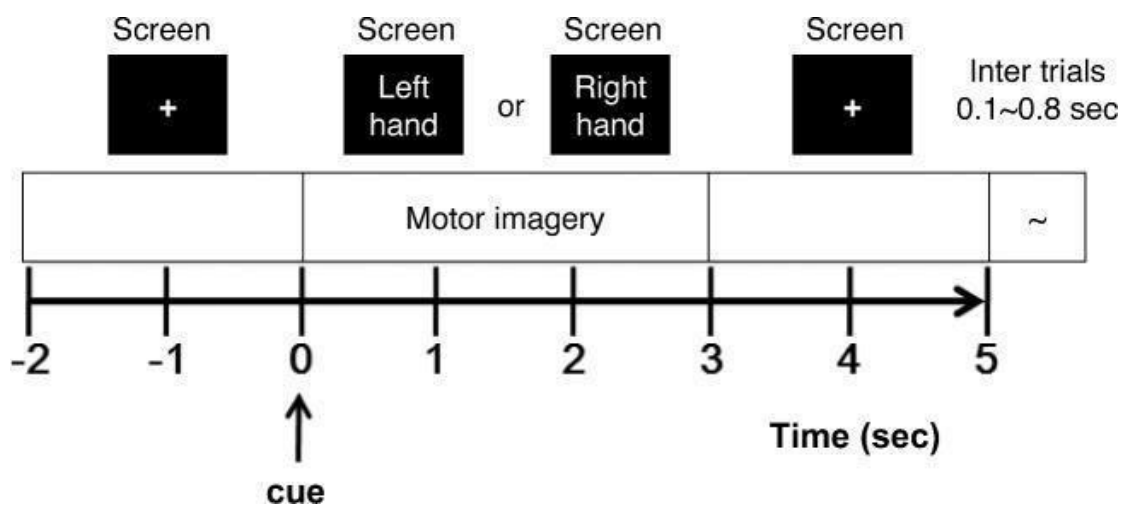
δημοσιεύτηκε πρόσφατα. Η καταγραφή έγινε με χρήση 64 Ag/AgCl ηλεκτροδίων με δειγματοληψία στα 512 Hz. Η τοποθέτηση των ηλεκτροδίων έγινε βάσει του διεθνούς 10-10 συστήματος, όπως φαίνεται στην Εικόνα 3.1. Το dataset αποτελείται από ένα συνδυασμό δεδομένων καλής διαχωριστικότητας (38 χρήστες), καθώς και δεδομένων λιγότερο καλής (14 χρήστες).



Εικόνα 3.1 Το διεθνές σύστημα 10 - 10 για πείραμα EEG 64 καναλιών [10]

### Κ.3.2.1 Το Πείραμα

**Πραγματική κίνηση:** Στην αρχή κάθε δοκιμής, η οθόνη που παρακολουθεί ο χρήστης είναι μαύρη με έναν σταυρό στο κέντρο για 2 δευτερόλεπτα. Η οθόνη δείχνει μετά με τυχαίο τρόπο οδηγίες για δεξιά ή αριστερή κίνηση χεριού, όπως φαίνεται στην Εικόνα 3.2 και ο χρήστης εκτελεί την κίνηση, σύμφωνα με την οθόνη, για 3 δευτερόλεπτα. Έπειτα, ξαναεμφανίζεται ο σταυρός για ένα τυχαίο διάστημα περίπου 2 δευτερολέπτων. Η διαδικασία πραγματικής κίνησης του χεριού επαναλαμβάνεται 20 φορές για κάθε κλάση.




Εικόνα 3.2 Παράδειγμα μιας δοκιμής του πειράματος [10]


**Νοερή κίνηση:** Η ίδια διαδικασία έπειτα επαναλαμβάνεται, ωστόσο αυτή τη φορά οι χρήστες φαντάζονται την κίνηση και την «εκτελούν» νοερά, σύμφωνα με τις οδηγίες στην οθόνη. Η καταγραφή για Νοερή Κίνηση επαναλήφθηκε 100-120 φορές. Ανά 20 δοκιμές, δόθηκε στον χρήστη ένα διάλειμμα το πολύ 4 λεπτών, ενώ παράλληλα υπολογίστηκε η απόδοση της κατηγοριοποίησης και έγινε ενημέρωση στον χρήστη, ώστε να του δοθεί περισσότερο κίνητρο για να εστιάσει στο πείραμα.

#### Κ.3.2.2 Διαχωριστικότητα δεδομένων ανά χρήστη

Έγινε μελέτη και ιεράρχηση αποτελεσμάτων από όλους τους χρήστες, οι οποίοι κατηγοριοποιήθηκαν σε «καλούς» και «κακούς». Σύμφωνα με τους συγγραφείς που διεξήγαγαν το πείραμα, στους «κακούς» χρήστες υπήρχε βαθμός συσχέτισης των σημάτων EMG μεταξύ της συνεδρίας με Νοερή Κίνηση και της συνεδρίας με πραγματική κίνηση. Στην Εικόνα 3.3 παρουσιάζεται η απόδοση της ταξινόμησης με cross-validation, η οποία έγινε με Common Spatial Pattern (CSP) και Fischer's Linear Discriminant Analysis (FLDA). Με κίτρινο ρόμβο φαίνεται για κάθε χρήστη η τυχαία κατάσταση, όπου οι χρήστες που δεν την περνάνε, αξιολογούνται ως κακοί χρήστες. Οπότε, έχουμε 38 χρήστες με καλή διαχωριστικότητα. Στην Εικόνα 3.4 φαίνεται η απόδοση κατηγοριοποίησης σε αύξουσα σειρά, οπότε στον οριζόντιο άξονα, λόγω ταξινόμησης, οι αριθμοί των χρηστών δεν αντιστοιχούν στους αντίστοιχους χρήστες.



Εικόνα 3.3 Ποσοστά ταξινόμησης για κάθε χρήστη του συνόλου δεδομένων. [10]



Εικόνα 3.4 Η ευστοχία του συνόλου δεδομένων ταξινομημένη σύμφωνα με την απόδοση των χρηστών. [10]

### Κ.3.3 Σχετική Έρευνα

Η έρευνα στο τομέα του BCI στοχεύει στην αυτόματη μετάφραση των νευρικών εντολών σε σήματα ελέγχου, ταξινομώντας τα χαρακτηριστικά μοτίβα από τα καταγεγραμμένα σήματα ηλεκτροεγκεφαλογράμματος (EEG) διαφόρων νοητικών διεργασιών (π.χ. φανταστικές κινήσεις χεριών και ποδιών). Εδώ παρουσιάζουμε τις πιο δημοφιλείς μεθόδους ταξινόμησης χαρακτηριστικών από σήματα EEG, τα οποία έχουν υποστεί μια προεπεξεργασία με τη χρήση κοινών χωρικών προτύπων (Common Spatial Pattern ή CSP). Σκοπός της παρούσας ενότητας είναι να αναδείξει τα πλεονεκτήματα και τις αδυναμίες των μεθόδων αυτών, ώστε να διαφανεί γιατί επιλέξαμε τη δική μας προσέγγιση.

Οι έρευνες πάνω στην ταξινόμηση EEG μέσω της χρήσης μεθόδων μηχανικής μάθησης έχει αποδειχθεί ότι παρέχουν ικανοποιητικά αποτελέσματα σε περιορισμένα περιβάλλοντα, όπως ένα εργαστήριο. Ωστόσο, σε σενάρια πραγματικού κόσμου (μη ελεγχόμενο περιβάλλον) προκύπτουν διάφορες προκλήσεις. Κάθε σύστημα BCI μπορεί να μοντελοποιηθεί ως ένα σύστημα αναγνώρισης προτύπων που αναγνωρίζει την πρόθεση του χρήστη, βάσει των χαρακτηριστικών σε σήματα από εγκεφαλική δραστηριότητα. Μέσω πειραμάτων BCI, με πολλές εκπαιδευτικές συνεδρίες, το σύστημα έχει ένα επαρκές σύνολο δεδομένων, ώστε να μπορεί να προβλέψει συγκεκριμένες διαδικασίες για μη εκπαιδευτικές συνεδρίες. Ωστόσο, τα σήματα EEG είναι εκ φύσεως μη-στατικά και συνήθως με πολύ θόρυβο, ειδικά όταν θέλουμε οι μη εκπαιδευτικές συνεδρίες να γίνονται σε πραγματικές συνθήκες, όπου έχουμε αύξηση της χρονικής μεταβλητότητας των καταγεγραμμένων σημάτων [5][6][7]. Αυτό

συμβαίνει, διότι οι αλλαγές στη συμπεριφορά και τη διανοητική κατάσταση του χρήστη επηρεάζουν άμεσα τα σήματα και επίσης έχουμε και θόρυβο από διάφορα άλλα παρασιτικά σήματα που σχετίζονται με τους μύες κ.α. (EMG, EOG) [12]. Έτσι, τα μοτίβα που παρατηρούνται κατά την εκπαίδευση μπορεί να διαφέρουν απ' αυτά μιας επόμενης συνεδρίας. Το πρόβλημα λοιπόν εντοπίζεται στη μη στάσιμη φύση των σημάτων EEG, η οποία έχει ως αποτέλεσμα σημαντική χρονική μεταβλητότητα στα σήματα. Αυτή η μεταβλητότητα, όπως αναφέρθηκε, μπορεί να σχετίζεται, είτε με την εσωτερική λειτουργία του εγκεφάλου, όπως με την κόπωση και την προσοχή, είτε με εξωτερικούς παράγοντες, όπως η πολυπλοκότητα του περιβάλλοντος που επηρεάζει τις αισθήσεις (όραση, ακοή, κ.α.) [12]. Η αντιμετώπιση λοιπόν της μη στάσιμης φύσης των σημάτων EEG είναι κρίσιμος παράγοντας για ένα αποδοτικό σύστημα BCI, ειδικά αν προορίζεται για εφαρμογές στην καθημερινή ζωή.

Οι μέθοδοι ταξινόμησης σημάτων EEG μπορούν να χωριστούν σε δύο κύριες κατηγορίες. Στην πρώτη κατηγορία, ανήκουν οι μέθοδοι ταξινόμησης που λειτουργούν άμεσα στο πεδίο χρόνου ή συχνότητων [11]. Τέτοιες μέθοδοι προσπαθούν να μεγιστοποιήσουν τη διαχωριστικότητα μεταξύ των κλάσεων, αναλύοντας απευθείας το εύρος των καταγεγραμμένων σημάτων σε μια σειρά χρόνου EEG. Στη δεύτερη κατηγορία, ανήκουν μέθοδοι που χρησιμοποιούν κάποιο είδος προεπεξεργασίας δεδομένων, όπως χωρικό φιλτράρισμα. Τέτοιες μέθοδοι είναι οι αλγόριθμοι Common Spatial Pattern (CSP) και xDawn [13][14], οι οποίοι στη συνέχεια συνδυάζονται με έναν γραμμικό ή μη γραμμικό ταξινομητή [15]. Η προεπεξεργασία δεδομένων, συνήθως υπό τη μορφή εποπτευόμενης μάθησης, ενισχύει τη γραμμική διαχωριστικότητα των σημάτων EEG, διευκολύνοντας έτσι την εργασία ταξινόμησης.

Οι μέθοδοι που ανήκουν στην πρώτη κατηγορία δύσκολα μπορούν να αντιμετωπίσουν τη χαμηλή αναλογία σήματος προς θόρυβο των δειγμάτων EEG, πόσο μάλλον τη μη στάσιμη φύση των αναπαραγόμενων σημάτων. Από την άλλη πλευρά, οι εργασίες προεπεξεργασίας και ταξινόμησης, για μεθόδους της δεύτερης κατηγορίας, εφαρμόζονται χωριστά με τρόπο «μαύρου κουτιού», δηλαδή δεν υπάρχει ροή της πληροφορίας παράλληλα μεταξύ των εργασιών προεπεξεργασίας και ταξινόμησης, παρά το γεγονός ότι αυτές είναι διαδοχικές. Αυτό δημιουργεί αρκετά προβλήματα, όπως η αυξημένη υπολογιστική πολυπλοκότητα, η δυσκολία στη μεταφορά της μάθησης και η προσαρμογή από προηγούμενες εκπαιδευτικές συνεδρίες και, σε πολλές περιπτώσεις, υψηλό κίνδυνο για υπερβολική προσαρμογή (overfit) στα δεδομένα εκπαίδευσης. Ενδιαφέρον παρουσιάζει η έρευνα στο [8], η οποία υιοθετεί τα πλεονεκτήματα των μεθόδων που ανήκουν στη δεύτερη κατηγορία, δηλαδή την καλύτερη ικανότητα διαχωρισμού των δειγμάτων EEG, ενώ ταυτόχρονα ενοποιεί την εργασία προεπεξεργασίας και ταξινόμησης σε ένα μόνο βήμα, προκειμένου να αποφευχθούν τα μειονεκτήματά τους.

Όπως αναλύσαμε σε προηγούμενο κεφάλαιο, οι περισσότερες εργασίες πάνω στην ταξινόμηση μοτίβων από σήματα EEG βασίζονται ως ένα βαθμό στην εκμετάλλευση του αλγορίθμου CSP. Αυτός ο αλγόριθμος είναι μια μέθοδος εξαγωγής χαρακτηριστικών που κατασκευάζει και εφαρμόζει βελτιστοποιημένα χωρικά φίλτρα σε δείγματα EEG με σκοπό τη βέλτιστη μεταξύ-κλάσεων διαχωριστικότητα [16][17]. Συγκεκριμένα, ο αλγόριθμος CSP προβάλλει τη χρονική διάσταση των δειγμάτων EEG

σε έναν υποχώρο, όπου οι διαφορές μεταξύ των κλάσεων είναι έντονες, ενώ οι ομοιότητες είναι μειωμένες. Αυτό συμβαίνει με τη μεγιστοποίηση της μέσης διακύμανσης της μιας κλάσης και της ταυτόχρονης ελαχιστοποίησης της άλλης [16]. Παρόλο που ο αρχικός αλγόριθμος CSP στοχεύει σε δυαδικά προβλήματα ταξινόμησης, έχουν προταθεί παραλλαγές αυτού του αλγορίθμου που αντιμετωπίζουν και προβλήματα ταξινόμησης πολλαπλών κλάσεων [18][19].

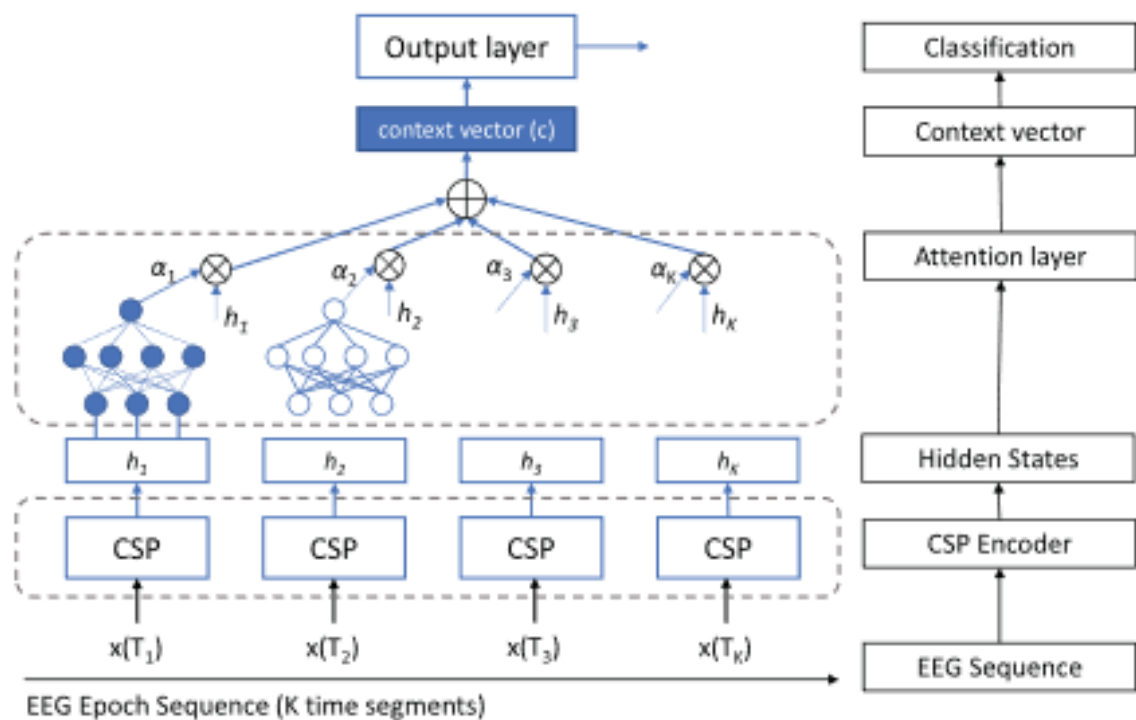
Λόγω της αποδοτικότητας του CSP, έχουν προταθεί πολλοί μέθοδοι για να αυξήσουν την ευρωστία του [20][21][22]. Σ' αυτές βλέπουμε να εισάγεται πληροφορία (π.χ. από άλλους χρήστες) και να γίνονται υποθέσεις (π.χ. ότι γειτονικοί νευρώνες έχουν παρόμοια συμπεριφορά, άρα γειτονικά ηλεκτρόδια θα δώσουν παρόμοιες καταγραφές) μαζί με χρήση κάποιων τεχνικών βελτιστοποίησης, ώστε να επιτύχουν καλύτερο φιλτράρισμα.

### K.3.3.1 Ενοποιημένο Νευρωνικό Δίκτυο για Ταξινόμηση EEG

Στην πλειονότητα των προσεγγίσεων γενικά το ζητούμενο είναι να εκμεταλλευτούν ένα πίνακα μέσης συνδιασποράς για κάθε κλάση, ώστε να έχουν όσο γίνεται καλύτερη μεταξύ των κλάσεων διαχωρισιμότητα. Ωστόσο, οι πίνακες αυτοί λόγω της μη στάσιμης φύσης των σημάτων μπορούν να οδηγήσουν σε μη αποδοτικά χωρικά φίλτρα και ως εκ τούτου σε μη έγκυρες προβλέψεις. Αν έχουμε δηλαδή σε ένα σύνολο δεδομένων για εκπαίδευση, όλες τις δοκιμές για μία κλάση να τις προβάλλουμε σε ένα μόνο πίνακα μέσης συνδιασποράς, το σύστημα δεν μπορεί να οδηγήσει πάντα σε αποδοτικά χωρικά φίλτρα.

Για το λόγο αυτό, η δουλειά στο [8] προτείνει ένα νέο μοντέλο, ώστε να ξεπεράσει την παραπάνω αδυναμία στον αλγόριθμο CSP. Αυτό το κάνει με τη χρήση πολλών διαφορετικών φίλτρων CSP σε συνδυασμό με έναν μηχανισμό ιεράρχησης. Ο μηχανισμός ιεράρχησης είναι σε θέση να αποφασίσει πως θα εκμεταλλευτεί τα φίλτρα CSP και να τα οργανώσει κατάλληλα, σύμφωνα με τα δεδομένα. Ο μηχανισμός ιεράρχησης είναι βασισμένος σε βαθύ νευρωνικό δίκτυο που είναι σε θέση να επεκτείνεται τόσο σε πλάτος, στο επίπεδο δηλαδή της εισόδου που είναι η χρονική διάσταση του σήματος EEG, όσο και σε μήκος που αφορά στα επίπεδα του νευρωνικού δικτύου, τα οποία είναι υπεύθυνα να αποφασίσουν τη σημασία των διαφόρων φίλτρων CSP. Η Εικόνα 3.5 δείχνει μια γενική απεικόνιση της αρχιτεκτονικής που υλοποιήθηκε στο [8].





Εικόνα 3.5 Το γενικό σχήμα της αρχιτεκτονικής που προτείνεται στο [8].

Συνοπτικά, πρόκειται για μια ευέλικτη δομή ταξινόμησης σημάτων EEG που προσπαθεί να συγκεντρώσει πολλές από τις προσεγγίσεις του CSP σ' ένα απ' άκρο σ' άκρο ενιαία εκπαιδευσιμο νευρωνικό δίκτυο. Η αρχιτεκτονική συγκεντρώνει τα εξής πλεονεκτήματα:

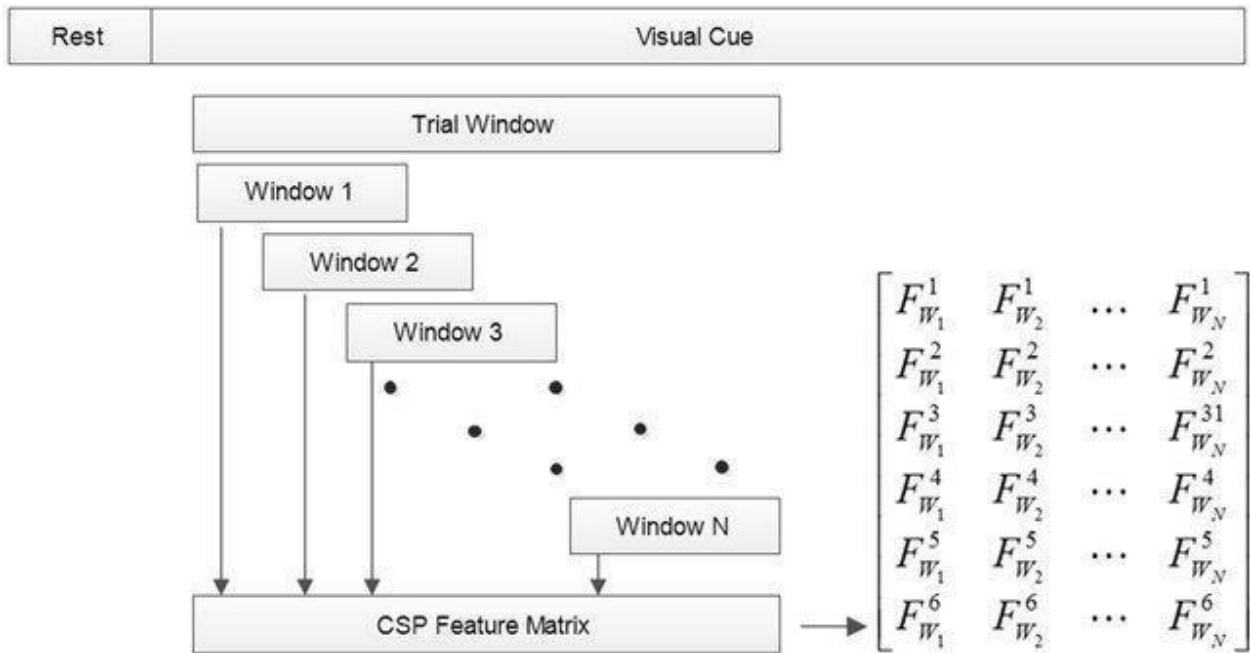
- Ενσωματώνει προσεγγίσεις που λειτουργούν τόσο στο πεδίο του χρόνου, όσο και στο πεδίο του χώρου.
- Επιδέχεται εκπαίδευση απ' άκρο σ' άκρο χρησιμοποιώντας τον αλγόριθμο backpropagation.
- Συνδυάζει με καινοτόμο τρόπο το χωρικό φιλτράρισμα από κατατμημένο χρονικά σήμα με επικάλυψη μεταξύ των τμημάτων.
- Με τη συγκεκριμένη αρχιτεκτονική και την κατάλληλη χρήση πολλαπλών CSP συμβάλει στην αντιμετώπιση της χρονικής μεταβλητότητας, κυρίως στην περίπτωση που αυτή οφείλεται σε διαφορές από συνεδρία σε συνεδρία.

### K.3.3.2 OPTICAL Ταξινόμητης

Στην έρευνα [9] παρουσιάζεται μία πρωτότυπη μέθοδος για ταξινόμηση σημάτων EEG βασισμένων σε Νοερή Κίνηση. Ως βασική ιδέα προτείνεται ένας συνδυασμός Κοινών Χωρικών Προτύπων (CSP) και δικτύων διαρκών μονάδων με βραχυπρόθεσμη μνήμη



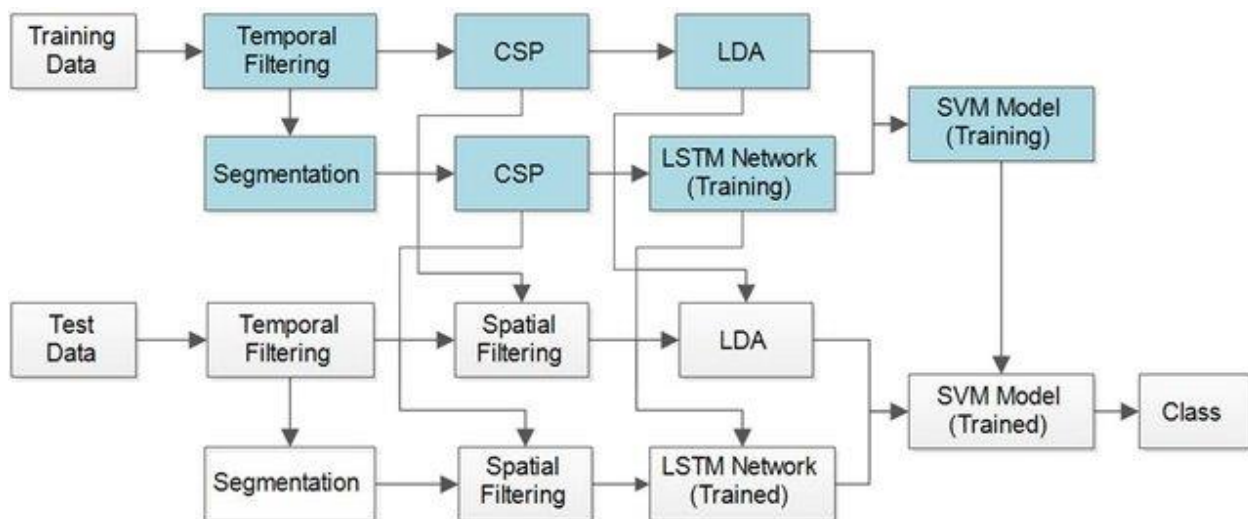
(LSTM), απ' όπου παίρνει και το όνομα της αυτή η προσέγγιση (Optimized CSP and LSTM classifier).



Εικόνα 3.6 Η διαδικασία εξαγωγής χαρακτηριστικών με χρήση κατάτμησης στη μέθοδο OPTICAL. [9]

Η καινοτομία που εισάγεται εδώ είναι να χρησιμοποιηθούν δύο παράλληλες δομές CSP. Η πρώτη δομή παίρνει απευθείας δεδομένα από το σύνολο προς εκπαίδευση, τα φιλτράρει χωρικά, και μετά εφαρμόζει Ανάλυση Γραμμικής Διάκρισης (LDA) μετασχηματίζοντας κατάλληλα τα χαρακτηριστικά που εξήχθησαν από το χωρικό φιλτράρισμα σε ένα μονοδιάστατο χαρακτηριστικό. Απ' την άλλη πλευρά, στο δεύτερο σετ CSP διαμορφώνεται ένας πίνακας από πολλά φίλτρα CSP, τα οποία παίρνουν τα δεδομένα μέσα από μια διαδικασία κατάτμησης, όπως φαίνεται στην Εικόνα 3.6.

Η διαδικασία αυτή θυμίζει τη προσέγγιση του [8] και στην ουσία αυτό που γίνεται είναι κάθε δοκιμή του συνόλου δεδομένων EEG να χωρίζεται σε μικρότερα τμήματα μήκους  $l$  στοιχείων. Στα παράθυρα υπάρχει μία μεταξύ τους επικάλυψη  $t$  στοιχείων και τελικά η δοκιμή EEG χωρίζεται σε  $N$  τμήματα. Ενώ η γενική διαδικασία μοιάζει πολύ με αυτή του [8], η κατάτμηση εδώ δεν γίνεται στο πεδίο του χρόνου, αλλά απευθείας στα δείγματα EEG. Τα τμήματα αυτά στη συνέχεια χρησιμοποιούνται για να εφαρμοστούν τα χωρικά φίλτρα CSP, διαμορφώνοντας τον πίνακα χαρακτηριστικών, όπως φαίνεται στην Εικόνα 3.6. Η διαδικασία αυτή ακολουθείται για όλες τις δοκιμές EEG του συνόλου δεδομένων, ώστε να διαμορφωθεί τελικά ένας πίνακας χαρακτηριστικών για όλο το εκπαιδευσιμο σύνολο δεδομένων. Ο πίνακας αυτός αποτελεί και την είσοδο για την LSTM μονάδα. Όλη η αρχιτεκτονική φαίνεται στο Σχήμα 3.7.



Εικόνα 3.7 Η αρχιτεκτονική της μεθόδου OPTICAL. [9]

Ο πίνακας χαρακτηριστικών από τη δεύτερη δομή CSP περιέχει, για κάθε δοκιμή EEG αντίστοιχα, τον πίνακα χαρακτηριστικών της. Αυτοί οι πίνακες για την κάθε δοκιμή EEG είναι οι ακολουθιακές εισόδους για το LSTM. Η δομή του LSTM αποτελείται από το επίπεδο εισόδου που παίρνει την ακολουθιακή είσοδο, και στη συνέχεια δύο διαδοχικά επίπεδα LSTM με 100 και 20 μονάδες αντίστοιχα, και ένα επίπεδο εξόδου που εφαρμόζει παλινδρόμηση. Εδώ, λόγω παλινδρόμησης στο τελικό επίπεδο της LSTM μονάδας, φτάνει στην έξοδο ένα μονοδιάστατο διάνυσμα.

Έτσι, τέλος συνδυάζονται οι έξοδοι των LDA και LSTM και δίνονται ως είσοδος στη δομή ταξινόμησης του συστήματος, δηλαδή σε μια μηχανή διανυσμάτων υποστήριξης (SVM), η οποία χρησιμοποιώντας τα χαρακτηριστικά, όπως διαμορφώθηκαν από το σύνολο δεδομένων, προχωράει στην εκπαίδευση όλου του συστήματος. Περαιτέρω ανάλυση για τα πλεονεκτήματα αυτής της μεθόδου θα γίνει στο Κεφάλαιο 5, στην ενότητα Συζήτηση, όπου αναλύουμε και συγκρίνουμε τη μέθοδο αυτή με τη δική μας υλοποίηση.

## Κεφάλαιο 4 Η συνεισφορά μας

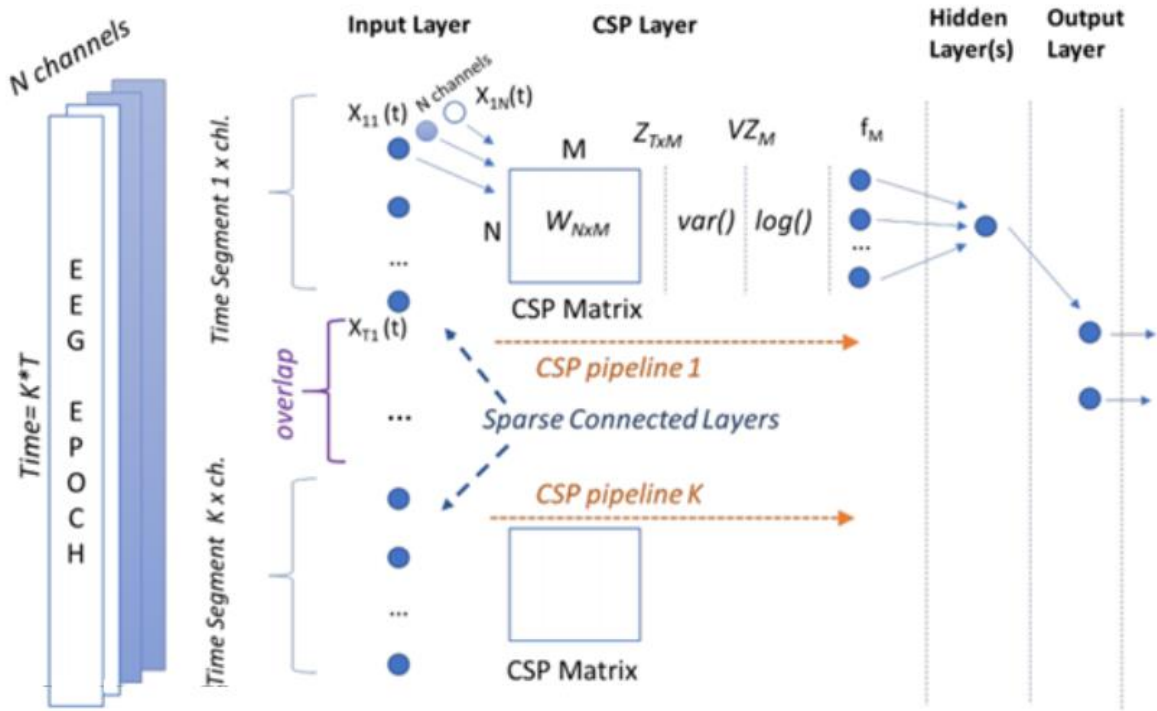
Στην παρούσα διπλωματική εργασία υλοποιήθηκε εξ αρχής μια απλοποιημένη εκδοχή της αρχιτεκτονικής που προτείνεται στο [8], δηλαδή του ενοποιημένου CSP και Deep Neural Network σχήματος και σε πρώτη φάση συγκρίθηκε με τον αλγόριθμο LRCSP [23], που είναι ο αλγόριθμος αναφοράς του, με σκοπό να δούμε την ακρίβεια της προσέγγισής μας σε σχέση με την πρωτότυπη. Σε δεύτερη φάση συγκρίνουμε αυτή την αρχιτεκτονική (Unified Neural Network, UniNNet) με υπόλοιπες δημοφιλείς προσεγγίσεις και βασικά με την αρχιτεκτονική OPTICAL [9], που είναι σχετικά πρόσφατη και δείχνει να υπερέχει έναντι άλλων. Η σύγκριση των δύο έχει ενδιαφέρον, για να δούμε πως ανταποκρίνονται στο ίδιο σύνολο δεδομένων δύο προσεγγίσεις που φαίνεται να αντιμετωπίζουν καλά τη μη στάσιμη φύση των σημάτων EEG.

### K.4.1 UniNNet

Ο προτεινόμενος αλγόριθμος βασίζεται σε μια αρχιτεκτονική βαθύς νευρωνικού δικτύου (end-to-end trainable) που διαδίδεται τόσο σε βάθος όσο και σε πλάτος. Τα βασικά συστατικά αυτής της αρχιτεκτονικής είναι τα επίπεδα φίλτρων CSP, που τα πλεονεκτήματά τους, προσφέρουν ευρωστία σε σχέση με τη χρονική μεταβλητότητα, παρά τις μη στατικές ιδιότητες του σήματος. Η τεχνική που συμβάλλει σε αυτό είναι ότι χωρίζεται κάθε δοκιμή (στο πεδίο του χρόνου) σε διαφορετικά τμήματα, ορίζοντας ανεξάρτητους παράλληλους τομείς. Στη συνέχεια, γίνεται προεπεξεργασία στο σήμα που φτάνει μέχρι τα κρυφά επίπεδα. Αυτή η διαδικασία κατάτμησης είναι παρόμοια με το να φιλτράρουμε την είσοδο, σύμφωνα με κάποιο βήμα ολίσθησης. Εδώ, για να διασφαλιστεί ότι κατά τη διαίρεση δε θα κόψουμε πιθανά μοτίβα που θα βοηθήσουν στην εξαγωγή χαρακτηριστικών, εισάγουμε μια παράμετρο επικάλυψης μεταξύ των γειτονικών τμημάτων. Με αυτή την προσαρμογή δηλαδή, μπορούμε να εγγυηθούμε ότι δεν θα διακόπτονται τα ERPs σε όλη τη διάρκεια της διαδικασίας κατάτμησης.

Για κάθε τμήμα χρόνου εφαρμόζουμε ένα στρώμα χωρικού φιλτραρίσματος CSP, το οποίο εκτελεί εσωτερικό γινόμενο μεταξύ της ροής των δεδομένων εισόδου  $\text{Tensor} [\text{batches} \times T (\text{samples}) \times N (\text{channels})]$  και του πίνακα βαρών  $W [N \times M]$  ακολουθούμενη από την εκτέλεση  $\text{var}()$  και  $\log()$ . Από αυτή την άποψη, για κάθε τμήμα χρόνου του  $T (\text{samples}) \times N (\text{channels})$ , κάθε επίπεδο CSP παράγει διάνυσμα χαρακτηριστικών πλάτους  $M$ . Τα διανύσματα αυτά μπορούν να υπολογιστούν ανεξάρτητα, καθώς βασίζονται σε διαφορετικά δεδομένα και αυξάνουν από αυτή την άποψη τον εγγενή παραλληλισμό του αλγορίθμου. Η εξωτερική διάσταση ( $M$ ) του πίνακα βαρών του επιπέδου CSP μπορεί να ρυθμιστεί ανάλογα με την κάθε περίπτωση και μπορεί να θεωρηθεί ως η βασική παράμετρος του κλασικού CSP.

Τελικά, όλα τα συστατικά, όπως φαίνεται στην Εικόνα 4.1, είναι ενσωματωμένα σε μία ενιαία αρχιτεκτονική, η οποία μπορεί να εκπαιδευτεί από άκρο σε άκρο χρησιμοποιώντας Back Propagation.



Εικόνα 4.1 Η αρχιτεκτονική της μεθόδου UniNNet. [10]

#### Κ.4.1.1 Εκπαίδευση

Για να υπολογίσει τις προβλέψεις το νευρωνικό UniNNet κάνει διάδοση προς τα εμπρός (forward propagation). Αν  $y_k$  είναι η απόκριση του CSP για το  $k$ -οστό τμήμα στα δεδομένα και  $K$  είναι ο αριθμός των τμημάτων, μετά την κατάτμηση που κάναμε στο πεδίο του χρόνου, τότε η διάδοση στο νευρωνικό δίκτυο γίνεται ως εξής:

$$h_k = (y_k W_{1,k} + b_1)$$

$$f_k = S(h_k)$$

$$\alpha_{1|2} = \sigma(F V + b_2)$$


όπου  $H = [h_1, \dots, h_k, \dots, h_m]$ ,  $F = [f_1, \dots, f_k, \dots, f_m]$  είναι τα διανύσματα των συναρτήσεων ενεργοποίησης για τα κρυφά επίπεδα του δικτύου,  $W_1$ ,  $W_2$  είναι οι πίνακες βαρών για τα επίπεδα εισόδου και εξόδου αντίστοιχα και  $\alpha_{1|2}$  είναι η δυαδική έξοδος του συστήματος. Επίσης, το  $S(x)$  συμβολίζει τη σιγμοειδή συνάρτηση που χρησιμοποιείται ως συνάρτηση ενεργοποίησης και  $\sigma(x)$  συμβολίζει τη συνάρτηση softmax που χρησιμοποιούμε στην έξοδο για να την πάρουμε σε μορφή πιθανοτικής κατανομής.

Με την ίδια λογική τροφοδοτούνται παράλληλα και οι υπόλοιπες  $M$  είσοδοι από το CSP. Σκοπός είναι να μάθουμε τις παραμέτρους του δικτύου ( $W_1$ ,  $V$ ) που ελαχιστοποιούν την συνάρτηση κόστους, δηλαδή τη συνάρτηση που υπολογίζει κάθε

φορά πόσο κοντά ήταν οι προβλέψεις του δικτύου σε σχέση με τα δεδομένα του παραδείγματος που τροφοδοτήθηκε. Όλα τα βάρη αρχικοποιούνται τυχαία πριν από τη διαδικασία εκπαίδευσης. Στην Εικόνα 4.2. φαίνεται η αρχιτεκτονική του δικτύου.

Εικόνα 4.2 Η δομή του νευρωνικού δικτύου στη μέθοδο UniNNet. [10]

Για την εκπαίδευση της προαναφερόμενης Αρχιτεκτονικής, χρησιμοποιούμε τον



αλγόριθμο Backpropagation (BP). Ο αλγόριθμος BP χρησιμοποιεί μερικές παραγώγους για να βελτιστοποιήσει όλους τους συντελεστές του δικτύου (τόσο στα χωρικά, όσο και στα πλήρως συνδεδεμένα επίπεδα). Καθώς το χωρικό φιλτράρισμα λαμβάνει χώρα με εμπρόσθια μετάδοση μέσα σε μια πλήρη δοκιμή στα EEG, οι παράμετροι θα πρέπει να ενημερώνονται με οπίσθια μετάδοση μετά την πλήρη τροφοδοσία μιας πλήρους δοκιμής EEG (δηλ. stochastic gradient descent) στο δίκτυο ή μιας παρτίδας  $n$  δοκιμών EEG (στην περίπτωση batch gradient descent). Με άλλα λόγια, κάθε παράδειγμα εκπαίδευσης (γνωστό και ως δοκιμή EEG) αποτελείται από  $T$  (samples)  $\times$   $N$  (κανάλια) και χρειαζόμαστε τουλάχιστον ένα τέτοιο, προκειμένου να εκτελέσουμε Backpropagation (BP).

Στο backpropagation, η συνάρτηση κόστους  $C$  υπολογίζει το σφάλμα  $\delta^L$  στο επίπεδο εξόδου.

Έχουμε γενικά,

$$\delta_j^L = \frac{\partial C}{\partial \alpha_j^L} \sigma'(z_j^i) \quad (4)$$

όπου  $\alpha_j^i$  είναι η έξοδος του  $j$ -οστού νευρώνα στο  $i$ -οστό στρώμα,

$$\delta_4 \in \mathbb{R}^{2 \times 1} \quad (5)$$

$$\delta_3 = [V^T \delta_4] \odot \sigma'(z^{(3)}) = [V^T \delta_4] \odot I \in \mathbb{R}^{M \times 1} \quad (6)$$

$$\delta_2 = \delta_3 \odot \sigma'(z^{(2)}) = \delta_3 \odot h^{-1} \in \mathbb{R}^{M \times 1} \quad (7)$$

$$\begin{aligned} \delta_{1,1} &= [I^T \delta_{2,1}] \odot \sigma'(z^{(1)}) \\ &= [I^T \delta_{2,1}] \odot \sigma'(y_1) \\ &= [I^T \delta_{2,1}] \odot \left( \frac{2}{T|W_1|} y_1 \right) \in \mathbb{R}^{T \times 1} \end{aligned} \quad (8)$$

$$\delta_1 \in \mathbb{R}^{T \times M} \quad (9)$$

$\sigma$  είναι η συνάρτηση ενεργοποίησης, και  $z_j^i = \sum(w_j^i \cdot \alpha^{i-1}) + b_j^i$  δηλαδή είναι η τιμή ενεργοποίησης ενός νευρώνα, πριν εφαρμοστεί η συνάρτηση ενεργοποίησης. Επίσης, ως συνάρτηση κόστους εφαρμόστηκε η cross-entropy loss, που συνδυάζεται με τη συνάρτηση ενεργοποίησης softmax που χρησιμοποιείται στο επίπεδο εξόδου.

Χρησιμοποιώντας τις παραπάνω σχέσεις, έχουμε:

$$\frac{\partial C}{\partial W} = X^T \delta_1 \quad (10)$$

Τέλος, με γνωστά τα  $\delta^L$ , όλων των επιπέδων, μπορούμε να ανανεώσουμε τις παραμέτρους του δικτύου ανάλογα και με τη παράμετρο του ποσοστού εκμάθησης  $e$ .

#### Κ.4.2 Αποτελέσματα

Σ' αυτό το σημείο αξιολογούμε την απόδοση της αρχιτεκτονικής που υλοποιήθηκε στη συγκεκριμένη εργασία. Η απόδοση του συστήματος ουσιαστικά αφορά στην αποδοτικότητα ως προς την ταξινόμηση σημάτων EEG. Ο απώτερος σκοπός είναι να συγκρίνουμε τη μεθοδολογία UniNNet, που ακολουθήσαμε εδώ, με την OPTICAL του [9], στο ίδιο σύνολο δεδομένων.

Προτού γίνει αυτή η σύγκριση, ελέγχουμε τη μεθοδολογία μας, πρώτον στο πως συμπεριφέρεται με διαφορετικές τιμές των καθολικών μεταβλητών της, και δεύτερον με τον αλγόριθμο LRCSP που αποτελεί και τον αλγόριθμο αναφοράς στο [8], ώστε να ελέγξουμε ότι η εκδοχή που υλοποιήσαμε εδώ δουλεύει παρόμοια με την πρωτότυπη.

Για την αξιολόγηση των αποτελεσμάτων χρησιμοποιήθηκε το σύνολο δεδομένων [10], δημόσια διαθέσιμο στην GigaScience βάση δεδομένων (GigaDB). Το σύνολο

δεδομένων χρησιμοποιεί 52 χρήστες και έχει 100 – 120 δοκιμές σε κάθε χρήστη για κάθε κλάση. Σε όλο το εύρος της αξιολόγησης ακολουθούμε 10-fold cross validation, πιο συγκεκριμένα για τη καθολική σύγκριση όλων των μεθόδων χρησιμοποιούμε 10×10-fold cross validation, ενώ στην αξιολόγηση της προσέγγισής μας, για τις διάφορες παραμέτρους του συστήματος, χρησιμοποιήσαμε 4×10-fold cross validation.

Το ενοποιημένο δίκτυο UniNNet που υλοποιήθηκε στο πλαίσιο αυτής της εργασίας το εκτελέσαμε και το αξιολογήσαμε σε δύο laptop οικιακής χρήσης, ένα HP (intel i7-8750H 2.2GHz, 12GB Ram) και ένα Acer (i3-2350M 2.2GHz, 4G RAM). Καθότι η υπολογιστική ισχύς ήταν περιορισμένη συμβιβαστήκαμε στην εσωτερική αξιολόγηση της μεθόδου UniNNet σε 4×10-fold cross validation και όχι σε 10×10.

Πριν μπούμε στη διαδικασία της αξιολόγησης, χρειάζεται να υπενθυμίσουμε, ότι ένα από τα βασικά πλεονεκτήματα που έχει η μεθοδολογία UniNNet, είναι η ευελιξία που παρέχει ως προς την δομή της. Στην ουσία μπορεί να δεχτεί ως υπερ-παραμέτρους το μέγεθος, τόσο στο πλάτος, όσο και στο μήκος του νευρωνικού δικτύου. Επίσης, είναι παραμετροποιήσιμο και ως προς τον αριθμό των φίλτρων CSP. Πιο συγκεκριμένα ως παραμέτρους το σύστημα δέχεται  $K$ ,  $M$ ,  $H_i$  όπου:

- $K$  είναι ο αριθμός των παράλληλων επικαλυπτόμενων τμημάτων που θα χωριστεί η είσοδος στο πεδίο του χρόνου.
- $M$  είναι ο αριθμός των φίλτρων CSP  $\leq N$  (Channels)
- $H_i$  είναι ο αριθμός των νευρώνων στο  $i$ -οστό κρυφό επίπεδο του νευρωνικού δικτύου.

Εμείς, για λόγους απλοποίησης του προβλήματος, θέσαμε το  $M=N$  σε όλα τα παραδείγματα κατά την αξιολόγηση και επίσης χρησιμοποιούμε μόνο ένα κρυφό επίπεδο. Τέλος, θέσαμε το ποσοστό επικάλυψης μεταξύ των παράλληλων τμημάτων  $K$  να είναι σε όλες τις περιπτώσεις 50%, το ποσοστό μάθησης  $e=0.001$  και οι επαναλήψεις κατά την εκπαίδευση του δικτύου 100.

Στους πίνακες που ακολουθούν φαίνεται το ποσοστό εσφαλμένης ταξινόμησης για κάθε μέθοδο ξεχωριστά και συνολικά για όλες τις μεθόδους μαζί, με κάποια βελτιστοποίηση.

Στον Πίνακα 1 φαίνονται οι μέθοδοι για απλό CSP, OPTICAL\* χωρίς βελτιστοποίηση και OPTICAL με Bayesian βελτιστοποίηση των παραμέτρων του LSTM δικτύου.

Στους Πίνακες 2 και 3 φαίνονται τα αποτελέσματα εσφαλμένης ταξινόμησης για την μέθοδο LRCSP και UniNNet. Στις μεθόδους αυτές εφαρμόσαμε τη διαδικασία βελτιστοποίησης σε δύο επίπεδα.

Το πρώτο επίπεδο αφορά το πεδίο των 10 επαναλήψεων στη διαδικασία 10-fold cross-validation, όπου είτε υπολογίζουμε έναν μέσο όρο (Average) από τις 10 επαναλήψεις, είτε παίρνουμε την καλύτερη (Best) τιμή μεταξύ των 10 επαναλήψεων, συμβολίζοντας την πρώτη περίπτωση με A και την δεύτερη περίπτωση με B.

Στο δεύτερο επίπεδο ελέγχουμε την απόδοση των δύο μεθόδων για διαφορετικές τιμές των υπερπαραμέτρων τους.

Πιο αναλυτικά, στη μέθοδο LRCSP παίρνουμε περιπτώσεις βάσει του αριθμού φίλτρων CSP που αποτελεί την υπερ-παράμετρο της LRCSP μεθόδου. Πιο συγκεκριμένα, παίρνουμε τρεις περιπτώσεις, μία με 1 χωρικό φίλτρο, μία με 6 χωρικά φίλτρα, δηλαδή όσα χρησιμοποιούν και στην έρευνα στο [9], και μία με 64, δηλαδή ένα για κάθε κανάλι/ ηλεκτρόδιο, σύμφωνα με το σύνολο δεδομένων GigaDB.

Για τη μέθοδο UniNNet, παίρνουμε τρεις περιπτώσεις για τις παραμέτρους  $K$  (παράλληλα επικαλυπτόμενα τμήματα) και  $H$  (αριθμός νευρώνων στο κρυφό επίπεδο). Μία περίπτωση με  $K=2, H=1$ , μία για  $K=2, H=3$  και μία για  $K=4, H=3$ .

Εδώ, πρέπει να αναφέρουμε ότι πήραμε αυθαίρετα το  $H=3$  βάσει και της παραμετροποίησης που έχει αντίστοιχα η δουλειά στο [8]. Επίσης, πήραμε και μία περίπτωση για  $H=1$ , ώστε να δούμε πόσο τα αποτελέσματα εξαρτώνται μόνο από το  $K$ , ωστόσο τελικά βλέπουμε ότι οι δύο παραπάνω νεύρωνες στη περίπτωση 2 και 3 συνεισφέρουν σημαντικά. Πιο συγκεκριμένα βλέποντας τον μέσο όρο των καλύτερων αποτελεσμάτων για όλο το σύνολο δεδομένων έχουμε τα εξής αποτελέσματα εσφαλμένης ταξινόμησης:

- περίπτωση  $K = 2, H = 1$  : 42.92%
- περίπτωση  $K = 2, H = 3$  : 27.53%
- περίπτωση  $K = 4, H = 3$  : 29.25%

Στο δεύτερο επίπεδο, όπου κάνουμε βελτιστοποίηση στο πεδίο των υπερπαραμέτρων παίρνουμε, αντίστοιχα με το πρώτο, δύο περιπτώσεις, μία για τον μέσο όρο (Average) και μία για την καλύτερη τιμή (Best), συμβολίζοντας την πρώτη περίπτωση με A (Average) και την δεύτερη περίπτωση με B (Best).

Συνολικά, και για τα δύο επίπεδα βελτιστοποίησης διακρίνουμε τις εξής 4 περιπτώσεις, όπου το πρώτο γράμμα αφορά στη βελτιστοποίηση στις υπερπαραμέτρους, ενώ το δεύτερο γράμμα αφορά στη βελτιστοποίηση στις επαναλήψεις 10×10-fold cross-validation:

- ❖ AA (Average of Averages)
- ❖ BA (Best of Averages)
- ❖ AB (Average of Bests)
- ❖ BB (Best of Bests)

Τέλος, ο Πίνακας 4 δείχνει συγκεντρωτικά τα αποτελέσματα για όλες τις μεθόδους.



**Πίνακας 1:** Το ποσοστό (%) εσφαλμένων ταξινομήσεων (ή ποσοστό αστοχίας) για τις μεθόδους **CSP**, **OPTICAL\***, **OPTICAL**

Subject	CSP	OPTICAL*	OPTICAL	Subject	CSP	OPTICAL*	OPTICAL
1	27 ± 13	21 ± 08	20 ± 09	27	53 ± 11	57 ± 10	55 ± 10
2	49 ± 09	46 ± 11	48 ± 12	28	20 ± 09	20 ± 08	19 ± 05
3	11 ± 07	09 ± 06	06 ± 06	29	55 ± 10	56 ± 11	57 ± 11
4	39 ± 09	24 ± 09	22 ± 10	30	44 ± 10	45 ± 09	45 ± 10
5	01 ± 02	01 ± 02	01 ± 02	31	45 ± 10	39 ± 10	38 ± 11
6	20 ± 09	17 ± 08	18 ± 08	32	50 ± 11	50 ± 13	49 ± 12
7	50 ± 08	48 ± 11	47 ± 08	33	49 ± 11	47 ± 11	44 ± 12
8	50 ± 11	44 ± 11	44 ± 12	34	44 ± 12	43 ± 10	42 ± 08
9	50 ± 10	44 ± 11	44 ± 10	35	19 ± 07	18 ± 09	18 ± 09
10	43 ± 12	31 ± 12	27 ± 10	36	47 ± 13	34 ± 12	31 ± 10
11	46 ± 10	49 ± 11	43 ± 10	37	27 ± 08	24 ± 08	23 ± 10
12	31 ± 10	35 ± 11	33 ± 09	38	53 ± 11	52 ± 12	52 ± 12
13	11 ± 06	15 ± 08	16 ± 08	39	29 ± 09	28 ± 11	27 ± 09
14	05 ± 04	05 ± 05	04 ± 04	40	49 ± 09	48 ± 11	49 ± 09
15	50 ± 10	43 ± 14	35 ± 11	41	26 ± 09	16 ± 07	15 ± 09
16	52 ± 12	52 ± 10	53 ± 12	42	56 ± 08	51 ± 11	52 ± 10
17	52 ± 09	50 ± 13	50 ± 09	43	07 ± 05	05 ± 05	04 ± 04
18	49 ± 12	49 ± 09	47 ± 08	44	11 ± 06	08 ± 07	11 ± 08
19	46 ± 11	43 ± 11	43 ± 09	45	46 ± 09	46 ± 08	48 ± 11
20	36 ± 10	28 ± 11	27 ± 10	46	31 ± 07	25 ± 08	25 ± 09
21	46 ± 11	40 ± 10	34 ± 11	47	27 ± 11	22 ± 08	26 ± 10
22	46 ± 11	47 ± 10	41 ± 10	48	44 ± 11	35 ± 11	22 ± 10
23	33 ± 10	20 ± 09	16 ± 08	49	11 ± 07	14 ± 07	13 ± 07
24	53 ± 11	47 ± 11	39 ± 10	50	00 ± 00	00 ± 00	00 ± 00
25	57 ± 11	49 ± 10	47 ± 14	51	50 ± 10	48 ± 11	47 ± 11
26	04 ± 04	04 ± 04	03 ± 03	52	43 ± 10	40 ± 11	38 ± 13
Average					36.3 ± 09	33.2 ± 09	31.8 ± 09

Παραπάνω φαίνεται το ποσοστό εσφαλμένων ταξινομήσεων των μεθόδων **CSP**, **OPTICAL** για κάθε *Subject* στο σύνολο δεδομένων *GigaDB*. Για κάθε *Subject* παρατηρούμε ανά μέθοδο την % εσφαλμένη ταξινόμηση ± την τυπική απόκλιση, όπως προέκυψαν μετά από 10×10-fold cross-validation. Η δεύτερη στήλη **OPTICAL\*** παρουσιάζει τα αποτελέσματα της μεθόδου **OPTICAL** χωρίς βελτιστοποίηση, ενώ η τρίτη στήλη παρουσιάζει τα αποτελέσματα της μεθόδου **OPTICAL** με βελτιστοποίηση των παραμέτρων ταξινόμησης.

**Πίνακας 2:** Τα % ποσοστά εσφαλμένης ταξινόμησης (% αστοχία) της μεθόδου **LRCSP** για διάφορες περιπτώσεις βελτιστοποίησης

Subject	LRCSP PARAMETER OPTIMIZATION				Subject	LRCSP PARAMETER OPTIMIZATION			
	AA	BA	AB	BB		AA	BA	AB	BB
01	60 ± 09	56 ± 09	44 ± 07	33 ± 07	27	48 ± 09	40 ± 09	33 ± 08	30 ± 08
02	53 ± 09	51 ± 09	35 ± 07	30 ± 07	28	12 ± 06	10 ± 06	03 ± 04	00 ± 04
03	50 ± 08	41 ± 08	33 ± 06	30 ± 06	29	50 ± 10	48 ± 10	33 ± 09	25 ± 09
04	65 ± 08	61 ± 08	48 ± 07	40 ± 07	30	63 ± 12	59 ± 12	33 ± 10	30 ± 10
05	19 ± 06	01 ± 06	13 ± 02	00 ± 02	31	49 ± 10	46 ± 10	30 ± 06	15 ± 06
06	28 ± 07	18 ± 07	20 ± 06	05 ± 06	32	68 ± 08	66 ± 08	58 ± 06	55 ± 06
07	66 ± 08	65 ± 08	52 ± 06	50 ± 06	33	55 ± 08	53 ± 08	40 ± 07	40 ± 07
08	40 ± 07	02 ± 07	18 ± 02	00 ± 02	34	20 ± 07	16 ± 07	08 ± 06	05 ± 06
09	59 ± 09	57 ± 09	50 ± 07	50 ± 07	35	62 ± 10	58 ± 10	48 ± 09	45 ± 09
10	55 ± 12	54 ± 12	40 ± 12	40 ± 12	36	64 ± 09	58 ± 09	45 ± 05	40 ± 05
11	62 ± 10	57 ± 10	48 ± 08	45 ± 08	37	24 ± 08	19 ± 08	10 ± 07	05 ± 07
12	53 ± 09	51 ± 09	40 ± 08	35 ± 08	38	65 ± 08	65 ± 08	50 ± 06	50 ± 06
13	09 ± 07	07 ± 07	00 ± 06	00 ± 06	39	35 ± 09	34 ± 09	25 ± 06	25 ± 06
14	45 ± 09	39 ± 09	30 ± 08	20 ± 08	40	55 ± 11	54 ± 11	40 ± 06	35 ± 06
15	49 ± 12	48 ± 12	35 ± 11	35 ± 11	41	62 ± 08	59 ± 08	50 ± 06	50 ± 06
16	52 ± 10	50 ± 10	38 ± 07	30 ± 07	42	57 ± 09	53 ± 09	40 ± 06	35 ± 06
17	67 ± 07	63 ± 07	55 ± 06	50 ± 06	43	01 ± 01	00 ± 01	00 ± 00	00 ± 00
18	52 ± 08	51 ± 08	40 ± 08	40 ± 08	44	07 ± 06	06 ± 06	00 ± 04	00 ± 04
19	52 ± 12	46 ± 12	30 ± 10	25 ± 10	45	51 ± 08	46 ± 08	35 ± 05	30 ± 05
20	64 ± 10	63 ± 10	38 ± 08	35 ± 08	46	51 ± 10	50 ± 10	38 ± 09	33 ± 09
21	60 ± 10	57 ± 10	38 ± 09	30 ± 09	47	18 ± 07	17 ± 07	05 ± 06	05 ± 06
22	48 ± 11	43 ± 11	35 ± 10	35 ± 10	48	51 ± 08	48 ± 08	38 ± 07	35 ± 07
23	45 ± 08	43 ± 08	33 ± 06	30 ± 06	49	09 ± 05	07 ± 05	00 ± 04	00 ± 04
24	56 ± 10	52 ± 10	43 ± 09	35 ± 09	50	00 ± 01	00 ± 01	00 ± 00	00 ± 00
25	56 ± 10	55 ± 10	38 ± 09	35 ± 09	51	47 ± 11	44 ± 11	33 ± 11	30 ± 11
26	04 ± 03	03 ± 03	00 ± 03	00 ± 03	52	45 ± 10	40 ± 10	28 ± 09	25 ± 09
					Average	44.9 ± 8	40.9 ± 8	30.8 ± 6	29.1 ± 6

Παραπάνω, φαίνεται το ποσοστό εσφαλμένων ταξινομήσεων της μεθόδου LRCSP για κάθε Subject στο σύνολο δεδομένων GigaDB. Για κάθε Subject παρατηρούμε ανά περίπτωση, την % εσφαλμένη ταξινόμηση ± την τυπική απόκλιση, όπως προέκυψαν μετά από 10×10-fold cross-validation. Είναι συνολικά τέσσερις περιπτώσεις βελτιστοποίησης σε δύο επίπεδα. Στο πρώτο επίπεδο αφορά το πεδίο των 10 επαναλήψεων στη διαδικασία 10-fold cross-validation, όπου είτε υπολογίζουμε στη μία περίπτωση έναν μέσο όρο (Average) από τις 10 επαναλήψεις, είτε παίρνουμε την καλύτερη (Best) τιμή μεταξύ των 10 επαναλήψεων στην άλλη περίπτωση. Στο δεύτερο επίπεδο ελέγχουμε την απόδοση της μεθόδου LRCSP μεταξύ διαφορετικού αριθμού φίλτρων CSP που αποτελεί την υπερπαραμέτρο της LRCSP μεθόδου. Και εδώ παίρνουμε δύο περιπτώσεις για μέσο όρο (Average) και καλύτερη τιμή (Best). Το επίπεδο 1 που αφορά τις επαναλήψεις στη διαδικασία cross-validation αναπαρίσταται από το δεύτερο γράμμα της κάθε στήλης. Το δεύτερο επίπεδο που αφορά τα διάφορα φίλτρα CSP αναπαρίσταται από το πρώτο γράμμα κάθε κάθε στήλης. Τελικά, διακρίνουμε τέσσερις περιπτώσεις AA, BA, AB, BB αντίστοιχα.

**Πίνακας 3:** Τα % ποσοστά εσφαλμένης ταξινόμησης (% αστοχία) της μεθόδου **UniNNet** για διάφορες περιπτώσεις βελτιστοποίησης

Subject	UNINNET PARAMETER OPTIMIZATION				Subject	UNINNET PARAMETER OPTIMIZATION			
	AA	BA	AB	BB		AA	BA	AB	BB
1	49 ± 16	38 ± 16	28 ± 11	00 ± 11	27	44 ± 14	35 ± 14	25 ± 08	05 ± 08
2	55 ± 04	42 ± 04	50 ± 00	30 ± 00	28	35 ± 13	23 ± 13	22 ± 07	05 ± 07
3	47 ± 06	42 ± 06	42 ± 02	30 ± 02	29	50 ± 07	45 ± 07	42 ± 04	35 ± 04
4	47 ± 09	40 ± 09	38 ± 07	35 ± 07	30	43 ± 08	38 ± 08	33 ± 00	15 ± 00
5	26 ± 08	04 ± 08	15 ± 02	00 ± 02	31	45 ± 06	35 ± 06	37 ± 02	20 ± 02
6	28 ± 13	11 ± 13	15 ± 11	00 ± 11	32	42 ± 12	37 ± 12	25 ± 05	20 ± 05
7	45 ± 03	40 ± 03	40 ± 02	38 ± 02	33	48 ± 08	40 ± 08	38 ± 04	35 ± 04
8	59 ± 07	43 ± 07	50 ± 02	45 ± 02	34	41 ± 10	33 ± 10	28 ± 02	20 ± 02
9	44 ± 05	43 ± 05	38 ± 00	33 ± 00	35	52 ± 07	48 ± 07	44 ± 05	40 ± 05
10	47 ± 11	42 ± 11	33 ± 04	15 ± 04	36	41 ± 16	29. ± 16	22 ± 06	02 ± 06
11	53 ± 05	50 ± 05	48 ± 02	45 ± 02	37	44 ± 06	41 ± 06	33 ± 02	25 ± 02
12	48 ± 05	40 ± 05	42 ± 00	35 ± 00	38	51 ± 08	48 ± 08	39 ± 02	28 ± 02
13	35 ± 13	23 ± 13	20 ± 02	00 ± 02	39	40 ± 12	37 ± 12	24 ± 03	10 ± 03
14	43 ± 03	40 ± 03	40 ± 00	40 ± 00	40	54 ± 04	46 ± 04	48 ± 02	40 ± 02
15	38 ± 16	22 ± 16	13 ± 08	00 ± 08	41	43 ± 07	38 ± 07	35 ± 02	30 ± 02
16	47 ± 12	42 ± 12	33 ± 02	18 ± 02	42	54 ± 10	47 ± 10	40 ± 04	40 ± 04
17	49 ± 04	42 ± 04	45 ± 02	40 ± 02	43	24 ± 15	14. ± 15	12 ± 05	00 ± 05
18	48 ± 04	40 ± 04	43 ± 00	40 ± 00	44	28 ± 07	11 ± 07	18 ± 04	00 ± 04
19	51 ± 06	43 ± 06	46 ± 00	35 ± 00	45	50 ± 07	47 ± 07	42 ± 04	35 ± 04
20	45 ± 10	37 ± 10	33 ± 05	30 ± 05	46	54 ± 08	51 ± 08	46 ± 07	42 ± 07
21	49 ± 06	43 ± 06	43 ± 02	40 ± 02	47	28 ± 10	13 ± 10	18 ± 06	05 ± 06
22	44 ± 08	40 ± 08	37 ± 00	30 ± 00	48	52 ± 07	47 ± 07	43 ± 06	40 ± 06
23	44 ± 11	36 ± 11	28 ± 06	05 ± 06	49	24 ± 10	09 ± 10	13 ± 02	05 ± 02
24	52 ± 07	51 ± 07	43 ± 06	40 ± 06	50	19 ± 05	00 ± 05	15 ± 00	00 ± 00
25	45 ± 18	35 ± 18	20 ± 10	05 ± 10	51	52 ± 08	45 ± 08	43 ± 05	35 ± 05
26	43 ± 17	33 ± 17	18 ± 06	05 ± 06	52	48 ± 10	45 ± 10	38 ± 07	30 ± 07
					Average	43.9 ± 8	35.8 ± 8	33.1 ± 3	23 ± 3

Παραπάνω φαίνεται το ποσοστό εσφαλμένων ταξινομήσεων της μεθόδου UniNNet για κάθε Subject στο σύνολο δεδομένων GigaDB. Για κάθε Subject παρατηρούμε ανά περίπτωση, την % εσφαλμένη ταξινόμηση ± την τυπική απόκλιση, όπως προέκυψαν μετά από 4×10-fold cross-validation. Είναι συνολικά τέσσερις περιπτώσεις βελτιστοποίησης σε δύο επίπεδα. Στο πρώτο επίπεδο αφορά το πεδίο των 10 επαναλήψεων στη διαδικασία 10-fold cross-validation, όπου είτε υπολογίζουμε στη μία περίπτωση έναν μέσο όρο (Average) από τις 10 επαναλήψεις, είτε παίρνουμε την καλύτερη (Best) τιμή μεταξύ των 10 επαναλήψεων στην άλλη περίπτωση. Στο δεύτερο επίπεδο ελέγχουμε την απόδοση της μεθόδου UniNNet σε διάφορες τιμές των υπερπαραμέτρων του συστήματος. Και εδώ παίρνουμε δύο περιπτώσεις για μέσο όρο (Average) και καλύτερη τιμή (Best). Το επίπεδο 1 που αφορά τις επαναλήψεις στη διαδικασία cross-validation αναπαρίσταται από το δεύτερο γράμμα της κάθε στήλης. Το δεύτερο επίπεδο που αφορά τις υπερπαραμέτρους αναπαρίσταται από το πρώτο γράμμα κάθε στήλης. Τελικά, διακρίνουμε τέσσερις περιπτώσεις AA, BA, AB, BB αντίστοιχα.

**Πίνακας 4:** Συγκεντρωτικά τα % ποσοστά εσφαλμένης ταξινόμησης για όλες τις μεθόδους.

Subject	CSP	OPTICAL*	OPTICAL	LRCSP				UNINNET			
				AA	BA	AB	BB	AA	BA	AB	BB
1	27	21	20	60	56	44	33	49	38	28	00
2	49	46	48	53	51	35	30	55	42	50	30
3	11	09	06	50	41	33	30	47	42	42	30
4	39	24	22	65	61	48	40	47	40	38	35
5	01	01	01	19	01	13	00	26	04	15	00
6	20	17	18	28	18	20	05	28	11	15	00
7	50	48	47	66	65	52	50	45	40	40	38
8	50	44	44	40	02	18	00	59	43	50	45
9	50	44	44	59	57	50	50	44	43	38	33
10	43	31	27	55	54	40	40	47	42	33	15
11	46	49	43	62	57	48	45	53	50	48	45
12	31	35	33	53	51	40	35	48	40	42	35
13	11	15	16	09	07	00	00	35	23	20	00
14	05	05	04	45	39	30	20	43	40	40	40
15	50	43	35	49	48	35	35	38	22	13	00
16	52	52	53	52	50	38	30	47	42	33	18
17	52	50	50	67	63	55	50	49	42	45	40
18	49	49	47	52	51	40	40	48	40	43	40
19	46	43	43	52	46	30	25	51	43	46	35
20	36	28	27	64	63	38	35	45	37	33	30
21	46	40	34	60	57	38	30	49	43	43	40
22	46	47	41	48	43	35	35	44	40	37	30
23	33	20	16	45	43	33	30	44	36	28	05
24	53	47	39	56	52	43	35	52	51	43	40
25	57	49	47	56	55	38	35	45	35	20	05
26	04	04	03	04	03	00	00	43	33	18	05
27	53	57	55	48	40	33	30	44	35	25	05
28	20	20	19	12	10	03	00	35	23	22	05
29	55	56	57	50	48	33	25	50	45	42	35
30	44	45	45	63	59	33	30	43	38	33	15
31	45	39	38	49	46	30	15	45	35	37	20
32	50	50	49	68	66	58	55	42	37	25	20
33	49	47	44	55	53	40	40	48	40	38	35
34	44	43	42	20	16	08	05	41	33	28	20
35	19	18	18	62	58	48	45	52	48	44	40
36	47	34	31	64	58	45	40	41	29	22	02
37	27	24	23	24	19	10	05	44	41	33	25
38	53	52	52	65	65	50	50	51	48	39	28
39	29	28	27	35	34	25	25	40	37	24	10
40	49	48	49	55	54	40	35	54	46	48	40
41	26	16	15	62	59	50	50	43	38	35	30
42	56	51	52	57	53	40	35	54	47	40	40
43	07	05	04	01	00	00	00	24	14	12	00
44	11	08	11	07	06	00	00	28	11	18	00
45	46	46	48	51	46	35	30	50	47	42	35
46	31	25	25	51	50	38	33	54	51	46	42
47	27	22	26	18	17	05	05	28	13	18	05
48	44	35	22	51	48	38	35	52	47	43	40
49	11	14	13	09	07	00	00	24	09	13	05
50	00	00	00	00	00	00	00	19	00	15	00
51	50	48	47	47	44	33	30	52	45	43	35
52	43	40	38	45	40	28	25	48	45	38	30
Average	36.31	33.23	31.81	44.96	40.96	30.89	29.15	43.98	35.85	33.15	23.00




## Κεφάλαιο 5 Συμπεράσματα

### Κ.5.1 Συζήτηση

Σ' αυτή τη διπλωματική εργασία αναλύσαμε δύο καινοτόμες μεθόδους για MI-BCI, οι οποίες, όπως φαίνεται και από τους πίνακες επιδόσεων έχουν εξαιρετικά αποτελέσματα ταξινόμησης σε σχέση με άλλες συμβατικές μεθόδους, και ταυτόχρονα υπόσχονται πολλά σε θέματα αντιμετώπισης της χρονικής μεταβλητότητας των σημάτων EEG. Πιο συγκεκριμένα, η μέθοδος OPTICAL βλέπουμε να έχει καλά αποτελέσματα όσον αφορά στην ταξινόμηση σε πραγματικές συνθήκες, ενώ η μέθοδος UniNNet αντιμετωπίζει καλά τη χρονική μεταβλητότητα από συνεδρία σε συνεδρία.

Εμείς σε αυτή την εργασία, έχοντας ως δεδομένα τα πλεονεκτήματα της κάθε μεθόδου, συγκρίνουμε και τις δύο στο ίδιο σύνολο δεδομένων και προσπαθούμε να εξάγουμε κάποια βασικά συμπεράσματα.


Δεδομένου ότι, για τα αποτελέσματα στη μέθοδο OPTICAL έχουμε bayesian βελτιστοποίηση των παραμέτρων του δικτύου και σε πρώτο στάδιο έχουμε τη μέση τιμή από 10 επαναλήψεις 10-fold cross-validation, τότε για να κάνουμε απευθείας σύγκριση με τις άλλες μεθόδους, αυτή πρέπει να γίνει με την περίπτωση BA (Best of Average) των άλλων δύο μεθόδων. Από τον Πίνακα 4, βλέποντας το average, παρατηρούμε ότι γενικά υπερέχει η μέθοδος OPTICAL με 31.81% έναντι 40.96% (LRCSP) και 35.85% (UniNNet). Βλέπουμε ότι ειδικά με τη μέθοδο UniNNet είναι πολύ κοντά, αφού η διαφορά τους είναι μικρότερη της τυπικής απόκλισης ( $\pm 9$ ) για το OPTICAL. Επίσης, αν πάρουμε σαν μέτρο σύγκρισης τον αριθμό των subjects για τα οποία οι μέθοδοι δίνουν το καλύτερο αποτέλεσμα, τα πράγματα αλλάζουν. Όπως βλέπουμε στο διάγραμμα στο Σχήμα 5.1, το UniNNet έχει τα περισσότερα καλύτερα αποτελέσματα για το σύνολο δεδομένων με 22 στα 52 subjects. Ενώ οι άλλες μέθοδοι φαίνεται να είναι πιο εύστοχες με την LRCSP να «νικάει» με 9 μόνο subjects για ποσοστό  $< 15\%$  έναντι 7 των υπόλοιπων δύο, και για ποσοστό  $< 5\%$  να ισοβαθμούν OPTICAL και LRCSP.




Σχήμα 5.1 Ο αριθμός των subjects στα οποία κάθε μέθοδος έχει το καλύτερο ποσοστό

Η παραπάνω σύγκριση, όπως αναφέρθηκε, έγινε στο επίπεδο βελτιστοποίησης των υπερπαραμέτρων για την κάθε μέθοδο. Ωστόσο, η bayesian βελτιστοποίηση που γίνεται στο σύστημα OPTICAL υπερσχύει σε σχέση με την αυτή που εφαρμόσαμε εδώ στις μεθόδους LRCSP και UniNNet. Στη πρώτη περίπτωση πρόκειται για μια αυτοματοποιημένη μέθοδο που κοιτά σε μεγάλο εύρος στοιχείων, ώστε να βρεί το καλύτερο σύνολο παραμέτρων, ενώ στη δεύτερη έγινε χειροκίνητα και στην ουσία βάλαμε ένα σύνολο από κάποιες ενδεικτικές τιμές στις παραμέτρους για την κάθε μέθοδο.

Για να δούμε σε πλήρες εύρος μέχρι που μπορούν να φτάσουν τα αποτελέσματα των μεθόδων LRCSP και UniNNet έχει ενδιαφέρον να δούμε πως αποδίδουν και στην περίπτωση BB (Best of Best), όπου δεν παίρνουμε τη μέση τιμή των 10 επαναλήψεων, αλλά την καλύτερη εκ των 10 για να κάνουμε βελτιστοποίηση παραμέτρων. Εδώ βλέπουμε την μέθοδο UniNNet να υπερέχει κατά πολύ και κατά μέσο όρο στα ποσοστά εσφαλμένης ταξινόμησης με 23% σε σχέση με το 31.8% του OPTICAL και το 29.1% του LRCSP, αλλά και στα ποσοστά ευστοχίας, όπου όπως φαίνεται στα Σχήματα 5.2, 5.3, έχει το καλύτερο σκορ στο 46.2% του συνόλου δεδομένων, ενώ ταυτόχρονα είναι και το πιο εύστοχο σύστημα με 17 subjects με σκορ κάτω του 5%.



Σχήμα 5.2 Η % καλύτερη απόδοση ανά μέθοδο για το σύνολο δεδομένων H.CHO et al( δηλ. για πόσους χρήστες απ' τους 52 έχει την καλύτερη απόδοση κάθε μέθοδος)



Σχήμα 5.3 Ο αριθμός των subjects στα οποία κάθε μέθοδος έχει ποσοστό  $< 5\%$

#### Κ.5.2 Μελλοντική δουλειά

Μερικές προτάσεις για περαιτέρω ενασχόληση με το θέμα περιλαμβάνουν:

- Την υλοποίηση της μεθοδολογίας UniNNet σε υλικό και την βελτιστοποίηση των παραμέτρων του συστήματος για κάθε χρήστη.
- Την σύνδεση των δύο προσεγγίσεων UniNNet και OPTICAL σε μία ενιαία δομή, εκμεταλλευόμενοι τα πλεονεκτήματα και των δύο μεθόδων.

## Βιβλιογραφία

- [1] Niedermeyer, Ernst, Schomer, Donald L. Lopes da Silva, F. H., eds. *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, And Related Fields*. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins, 2011.
- [2] J. N. Mak and J. R. Wolpaw, "Clinical Applications of Brain—Computer Interfaces: Current State and Future Prospects," *IEEE Reviews in Biomedical Engineering*, vol. 2, pp. 187–199, 2009.
- [3] M. M. Moore, "Real-world applications for brain-computer interface technology," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 11, no. 2, pp. 162–165, Jun. 2003.
- [4] B. Z. Allison *et al.*, "Why use a BCI if you're healthy? Brain Computer Interfaces-Clinical Application View project recoveriX View project Why Use A BCI If You Are Healthy?," 2008. [Online]. Available: <https://www.researchgate.net/publication/225304559>.
- [5] S. Muthong, P. Vateekul, and M. Sriyudthsak, "Stacked probabilistic regularized LDA on partitioning non-stationary EEG data for left/right hand imagery classification," in *2016 IEEE EMBS Conference on Biomedical Engineering and Sciences (IECBES)*, Dec. 2016, pp. 301–306.
- [6] S. R. Liyanage, C. Guan, H. Zhang, K. K. Ang, J. Xu, and T. H. Lee, "Dynamically weighted ensemble classification for non-stationary EEG processing," *Journal of Neural Engineering*, vol. 10, no. 3, p. 036007, Jun. 2013.
- [7] X. Yu, P. Chum, and K.-B. Sim, "Analysis the effect of PCA for feature reduction in non-stationary EEG based motor imagery of BCI system," *Optik*, vol. 125, no. 3, pp. 1498–1502, Feb. 2014.
- [8] A. Nikitakis, K. Makantasis, N. Tampouratzis, and I. Papaefstathiou, "A Unified Novel Neural Network Approach and a Prototype Hardware Implementation for Ultra-Low Power EEG Classification," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 13, no. 4, pp. 670–681, Aug. 2019.
- [9] S. Kumar, A. Sharma, and T. Tsunoda, "Brain wave classification using long short-term memory network based OPTICAL predictor," *Scientific Reports*, vol. 9, no. 1, Dec. 2019. [Online]. Available: <https://doi.org/10.1038/s41598-019-45605-1>
- [10] H. Cho, M. Ahn, S. Ahn, M. Kwon, and S. C. Jun, "EEG datasets for motor imagery brain-computer interface," *GigaScience*, vol. 6, no. 7. Oxford University Press, Jul. 01, 2017.
- [11] A. R. Marathe, A. J. Ries, and K. McDowell, "Sliding HDCA: Single-Trial EEG Classification to Overcome and Quantify Temporal Variability," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 22, no. 2, pp. 201–211, Mar. 2014.
- [12] S. D. Muthukumaraswamy and K. D. Singh, "Visual gamma oscillations: The effects of stimulus type, visual field coverage and stimulus motion on MEG and EEG recordings," *NeuroImage*, vol. 69, pp. 223–230, Apr. 2013.



- [13] N. Robinson, A. P. Vinod, K. K. Ang, K. P. Tee, and C. T. Guan, "EEG-Based Classification of Fast and Slow Hand Movements Using Wavelet-CSP Algorithm," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 8, pp. 2123–2132, Aug. 2013.
- [14] B. Rivet, A. Souloumiac, V. Attina, and G. Gibert, "xDAWN Algorithm to Enhance Evoked Potentials: Application to Brain–Computer Interface," *IEEE Transactions on Biomedical Engineering*, vol. 56, no. 8, pp. 2035–2043, Aug. 2009.
- [15] R. Zhang *et al.*, "A new motor imagery EEG classification method FB-TRCSP+RF based on CSP and random forest," *IEEE Access*, vol. 6, pp. 44944–44950, Jul. 2018.
- [16] Z. J. Koles, "The quantitative extraction and topographic mapping of the abnormal components in the clinical EEG.," *Electroencephalography and clinical neurophysiology*, vol. 79, no. 6, pp. 440–7, Dec. 1991, [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/1721571>.
- [17] H. Ramoser, J. Muller-Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 441–446, Dec. 2000.
- [18] T. Yan, T. Jingtian, and G. Andong, "Multi-Class EEG Classification for Brain Computer Interface based on CSP," in *2008 International Conference on BioMedical Engineering and Informatics*, May 2008, pp. 469–472.
- [19] G. Dornhege, B. Blankertz, G. Curio, and K. Muller, "Increase information transfer rates in BCI by CSP extension to multi-class." *Neural Information Processing Systems*, January 2004, [Online]. Available: <https://koreauniv.pure.elsevier.com/en/publications/increase-information-transfer-rates-in-bci-by-csp-extension-to-mu>.
- [20] Haiping Lu, How-Lung Eng, Cuntai Guan, K. N. Plataniotis, and A. N. Venetsanopoulos, "Regularized Common Spatial Pattern With Aggregation for EEG Classification in Small-Sample Setting," *IEEE Transactions on Biomedical Engineering*, vol. 57, no. 12, pp. 2936–2946, Dec. 2010.
- [21] F. Lotte and Cuntai Guan, "Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 2, pp. 355–362, Feb. 2011.
- [22] Y. Zhang, Q. Zhao, G. Zhou, X. Wang, and A. Cichocki, "Regularized CSP with Fisher's criterion to improve classification of single-trial ERPs for BCI," in the *9th International Conference on Fuzzy Systems and Knowledge Discovery*, May 2012, pp. 891–895.
- [23] A. Yuksel and T. Olmez, "A Neural Network-Based Optimal Spatial Filter Design Method for Motor Imagery Classification," *PLOS ONE*, vol. 10, no. 5, p. e0125039, May 2015.
- [24] D. J. Mcfarland and J. R. Wolpaw, "Brain–Computer Interfaces for the Operation of Robotic and Prosthetic Devices," in *Advances in Computers*, Elsevier, 2010, pp. 169–187.
- [25] G. D. Johnson and D. J. Krusienski, "Computational EEG Analysis for Brain-Computer Interfaces," in *Biological and Medical Physics, Biomedical Engineering*, Springer Singapore, 2018, pp. 193–214.